

## Transfer Öğrenme Temelli Bitki Yaprak Hastalıklarının Tespiti İçin Karşılaştırmalı Bir Çalışma

Sevde SAZAK<sup>1</sup>, Selin Ceren BALSAK<sup>2</sup>, Hasan BADEM<sup>3</sup>

<sup>1</sup>Kahramanmaraş Sütçü İmam Üniversitesi, Bilgisayar Mühendisliği Bölümü, <sup>2</sup>Kahramanmaraş Sütçü İmam Üniversitesi, Ziraat Fakültesi, Bitki Koruma Bölümü, <sup>3</sup>Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü  
<sup>1</sup><https://orcid.org/0009-0000-9035-3261>, <sup>2</sup><https://orcid.org/0000-0002-2326-7520>, <sup>3</sup><https://orcid.org/0000-0002-4262-8774>

✉: [hbadem@ksu.edu.tr](mailto:hbadem@ksu.edu.tr)

### ÖZET

Bitkilerin sağlıklı bir şekilde yetiştirilmesi ve verimli ürün alınması için hastalıkların erken teşhisi kritik öneme sahiptir. Bitki hastalıklarının bir çiftçi tarafından görsel olarak tanımlanması genellikle zordur. Ancak, makine öğrenmesi yöntemleri kullanılarak, bitki hastalıkları tespiti sürecini daha hızlı ve hassas bir şekilde gerçekleştirilebilir. Bu sayede, ürün kayıplarını azaltarak, maliyetlerinin düşürülmesi ve tarımsal üretkenliğin artırılmasıyla genel ekonomik verimliliği yükseltebilmek mümkündür. Bu çalışmada, 12 farklı sağlıklı bitki ve 30 farklı hastalıkla bulaşık bitki yaprağı görüntüleri kullanılarak bitki hastalıklarının yapay zeka ile sınıflandırması amaçlanmıştır. Geliştirilen sistemde yapay zeka modeli olarak VGG16, VGG19, AlexNet, MobileNetV1 ve MobileNetV2 olmak üzere 5 farklı Evrişimli sinir ağı modeli kullanılmıştır. Tüm modeller eğitilmiş ve doğruluk değerleri üzerinden karşılaştırılmıştır. MobileNetV1 üzerinden %99,20 ile en yüksek doğruluk değeri elde edilmiştir. Önerilen yöntem, çeşitli performans analizlerinden geçirilerek doğrulanmıştır. Yapay zeka tabanlı bir web uygulama da son kullanıcı için geliştirilmiştir.

### Bitki Koruma

### Araştırma Makalesi

### Makale Tarihiçesi

Geliş Tarihi : 21/10/2024

Kabul Tarihi : 04/12/2024

### Anahtar Kelimeler

Bitki Yaprak Hastalığı  
Derin Öğrenme  
Transfer Öğrenme  
Evrişimli Sinir Ağı  
Görüntü Sınıflandırma

## A Comparative Study for Detection of Plant Leaf Diseases Based on Transfer Learning

### ABSTRACT

Early diagnosis of diseases is critical for growing plants in a healthy manner and obtaining productive products. Plant diseases are generally difficult to visually identify by a farmer. However, by using machine learning methods, the process of detecting plant diseases can be realized more quickly and precisely. Hence, it can reduce product losses, reduce costs, and increase overall economic efficiency by increasing agricultural productivity. In this study, classifying plant diseases with artificial intelligence has been aimed by using images obtained from 12 different images of healthy plants and plant leaves infected with 30 different diseases. In the developed system, 5 different Convolutional neural networks (CNN) models including VGG16, VGG19, AlexNet, MobileNetV1, and MobileNetV2, have been used as artificial intelligence models. All models have been trained and compared based on their accuracies. The highest accuracy value of 99.20% has been obtained by The MobileNetV1. The proposed method has been validated through various performance analyses. An artificial intelligence-based web-based application has also been developed for the end-user.

### Plant Protection

### Research Article

### Article History

Received : 21/10/2024

Accepted : 04/12/2024

### Keywords

Plant Leaf Disease  
Deep Learning  
Transfer Learning  
Convolutional Neural Network  
Image Classification

**Atıf İçin :** Sazak, S., Balsak, S. C., & Badem, H. (2025). Transfer Öğrenme Temelli Bitki Yaprak Hastalıklarının Tespiti İçin Karşılaştırmalı Bir Çalışma. *KSÜ Tarım ve Doğa Derg* 28 (1), 154-170. DOI: 10.18016/ksutarimdog.vi.1571202

**To Cite:** Sazak, S., Balsak, S. C., & Badem, H. (2025). A Comparative Study for Detection of Plant Leaf Diseases Based on Transfer Learning. *KSU J. Agric Nat* 28 (1), 154-170. DOI: 10.18016/ksutarimdog.vi.1571202

## GİRİŞ

Bitki hastalıkları, dünya çapında küresel gıda güvenliği ve çevresel sürdürülebilirlik açısından önemli riskler oluşturmakta ve etkilenen bölgelerin çevresel ve sosyo-ekonomik koşullarını olumsuz etkileyen doğrudan verimlilik ve biyolojik çeşitlilik kaybına yol açmaktadır (Ristaino ve ark., 2021). Bitkilerde hastalığa sebep olan canlı (biyotik): virüs, viroid, bakteri, molliküt (fitoplazma ve spiroplazma) ve fungus gibi patojenik mikroorganizmalar ile parazitik bitkiler ve cansız (abiyotik): sıcaklık, nem, ışık, besin elementi eksikliği veya fazlalığı, toprak yapısı ve pH gibi etkenler bulunmaktadır. Abiyotik faktörler geniş alanlarda bitkilere zarar verebilmelerine rağmen, patojenlerden farklıdır. Çünkü çoğalmazlar ve bitkiden bitkiye yayılmazlar. Kültürü yapılan bitki türleri arasında ortaya çıkan bulaşıcı hastalıklar gıda sürdürülebilirliği için ciddi bir tehdit oluşturmaktadır.

Patojenler konukçu bitkilerinden ihtiyaç duydukları besinleri absorbe ederek, enzim toksin, büyüme düzenleyicileri gibi biyokimyasallar salgılayarak fizyolojik olaylarında önemli değişikliklere sebep olurlar. Fizyolojik olaylar arasında, fotosentez, yaprak hastalıklarından birincil olarak etkilenir (Bastiaans, 1991; Lopes & Berger, 2001). Örneğin, yaprakların bir kısmını enfekte eden ve öldüren veya klorofilini yok eden bir patojen, bitkinin fotosentezinin, büyümesinin ve veriminin azalmasına vb. yol açar. Enfeksiyonun sonucu olarak da veriminin azalması, ürün kalitesinin düşmesi, hasat sonrası ürün bozulması, çok yıllık ürün plantasyonlarının yok olması ve bazı durumlarda diğer biyotik veya abiyotik faktörlere (örn. don) karşı duyarlılığın artması söz konusudur. Bu nedenle, bitki hastalıklarının doğru ve zamanında tespit edilmesi, hastalıkla mücadelenin erken dönemde başlanması ve böylece hastalığın yayılmasının önlenmesi açısından oldukça önemlidir. Enfekteli bitki, patojen-konukçu kombinasyonuna bağlı olarak çeşitli semptomlar (hastalık belirtileri) gösterir. Bu semptomlar bitkinin farklı organlarında görülebileceği gibi bitkinin tümünde de görülebilmektedir. Arazi koşullarında hastalıkların tespit edilmesi ve mücadelesinin başlanması, genellikle üretici ve uzmanların bilgi ve tecrübeleri doğrultusunda çıplak gözle yapılmaktadır. Çoğu zaman bu hastalıkların doğru zamanda tespit edilememesi mücadeleye geç başlanmasına neden olmaktadır. Bu durum gereksiz tarım ilacı (pestisit) kullanımı ile üretim maliyetinin artmasının yanı sıra çevresel kirlenmeye zemin hazırlamaktadır (Erdoğan, 2024). Ayrıca, insan sağlığına olumsuz etkiye neden olmaktadır. Bu hastalıkların kontrol altına alınması, sağlıklı bir tarım sistemi için kritik önem taşır. Dolayısıyla, hastalıkların etkili bir şekilde yönetilmesi, tarımsal sürdürülebilirliğin sağlanması ve gıda güvenliğinin korunması için önemli bir gerekliliktir. Çiftçiler veya uzmanlar, bitki yaprak hastalıklarını genel bir şekilde tanıyabilir ve teşhis edebilir. Bununla birlikte, bu yaklaşım zaman alıcı, maliyetli ve her zaman güvenilir değildir (Luckey, 2012). Makine öğrenimi ve derin öğrenmedeki son gelişmeler, bitki hastalıklarının tespit edilmesini kolaylaştırmıştır (Heltin Genitha ve ark., 2019; Harakannavar ve ark., 2022). Hastalıkların üretim alanındaki diğer bitkilere yayılmadan önce erken tespit edip sınıflandırarak ürün kaybının önlenmesi sağlar (Rajasekaran ve ark., 2020). Bu sayede hastalıkların erken teşhisi, çiftçilerin zamandan tasarruf etmesine ve bitki büyümesini teşvik etmesine yardımcı olabilir. Bitki yapraklarından hastalık tanımlaması ve sınıflandırması için görüntü işleme yöntemlerinin benimsenmesi üzerine gerçekleştirilen anket sonuçları, görüntü işleme tekniklerinin bitki büyümesini, verimliliği, kaliteyi ve ekonomik değeri artırdığını göstermiştir (Chouhan ve ark., 2019).

Derin öğrenme, son yıllarda, özellikle bitki yaprak hastalığı görüntülerini hassas ve hızlı bir şekilde tespit etmek ve sınıflandırmak için görüntü sınıflandırmasında önemli ölçüde ilerlemiştir (Abade ve ark., 2021). Transfer öğrenme (Zhao ve ark., 2022; Xu ve ark., 2022; Nigam ve ark., 2023; Ibarra-Pérez ve ark., 2024) ise, derin öğrenme modellerinin çeşitli dezavantajlarını giderir. Transfer öğrenme, daha önce öğrenilen bir görevden elde edilen bilgileri kullanarak öğrenmeyi geliştiren güçlü bir derin öğrenme tekniğidir (Mohanty ve ark., 2016). Transfer öğrenme modellerinin sınıflandırma birimi probleme özgü olarak yeniden eğitildiği için hesaplama maliyeti oldukça azalmaktadır. Bu sayede eğitim süresi ve hesaplama için donanım maliyetler azalır (Yosinski ve ark., 2014). Transfer öğrenme hesaplama karmaşıklığı ve kontrol parametreleri, kullanılan modelin karmaşıklık seviyesi ve katman sayısına göre belirlenir (Picon ve ark., 2019). Böylece transfer öğrenme, daha önce edinilmiş bilgileri etkili ve hızlı bir şekilde kullanarak nesne tespiti ve görüntü sınıflandırmasında önemli ilerlemelere yol açmaktadır (Wasswa ve ark., 2024).

Bu çalışmanın amacı, bitki hastalıklarının tespitinde beş farklı transfer öğrenme tekniğinin VGG16, VGG19 (Simonyan & Zisserman, 2014), AlexNet (Krizhevsky ve ark., 2012), MobileNetV1 (Howard ve ark., 2017) ve MobileNetV2 (Sandler ve ark., 2018) başarımını karşılaştırmaktır. En iyi sonucu veren model, geleneksel yöntemlere kıyasla daha yüksek doğruluk ve verimlilik sağlayarak tarımsal üretimde verimliliği ve sürdürülebilirliği artırmayı hedeflemektedir.

Bu çalışmada sırasıyla literatür özeti, materyal ve metot, bulgular ve tartışma bölümleri sunulmaktadır. En son çıkarımlar ve gelecek çalışmalar ile sonlandırılmaktadır.

## LİTERATÜR ÖZETİ

Literatürde, bitki hastalıklarının tespiti alanında bugüne kadar önemli araştırmalar yapılmıştır. Literatür taramasında transfer öğrenme ele alınan problem üzerinde iyi sonuçlar verdiği görülmektedir (Yang ve ark., 2019; Espejo-Garcia ve ark., 2021)

Nachtigall ve ark. (2016) tarafından yapılan çalışmada elma ağaçlarındaki hastalıkları tespit etmek ve sınıflandırmak için AlexNet mimarisi kullanılmışlardır. Sonuçlar, CNN tarafından elde edilen %97,3'lük bir doğruluk göstermiştir. Wang ve ark. (2017) elma hastalıklarının sınıflandırılması için en iyi model olarak transfer öğrenimi ile eğitilen VGG16 olduğunu ve %90,84 doğruluk verdiğini belirtmişlerdir. Walleign ve ark. (2018) soya fasulyesindeki hastalıkları sınıflandırmak için CNN sınıflandırıcısını kullanarak bir model tasarlamıştır. Modellerinin %99,32 doğruluk elde ettiklerini bildirmişlerdir. Dawei ve ark. (2019) bahçecilikte zararlıları tespit etmek için transfer öğrenimini kullanarak toplam 10 sınıfı tahmin edebilen model ile %93,84 doğruluğa ulaşmıştır. Ferentinos (2018) 25 farklı bitki hastalığının tanılanması için derin öğrenme sınıflandırma tekniğini uygulayarak, %99,53 doğruluk elde etmişlerdir. Chen ve ark. (2020) bitki hastalıklarının tespit etmek için transfer öğrenimini incelemişlerdir. VGGNet-19 modelini seçilmesiyle önerilen yaklaşım, %92'lik doğruluk sağlamıştır. Cruz ve ark. (2017) *Xylella fastidiosa* etmeninin zeytinde neden olduğu Xylella yaprak yanıklığı hastalığının tespitini transfer öğrenme ile gerçekleştirmiştir. Yapılan analiz sonucunda, semptom taşıyan zeytin yapraklarının kullanılmasıyla hastalığın tespit edilmesindeki başarı oranının yaklaşık %98,60 olduğu görülmüştür. Marzougui ve ark. (2020) tarafından gerçekleştirilen çalışmada CNN ile bitki hastalıklarının tespit etmek için ResNet modelini kullanılmıştır. Çalışmada, 500 bitki görüntüsünden oluşan özelleştirilmiş bir veri seti kullanılmıştır. Tasarlanan model ile görüntüleri sağlıklı ve hastalıklı olmak üzere iki kategoriye ayırmakta olup, geliştirilen sistem ile son teknolojiye önerilenlerden daha iyi tespit performansları elde ettiklerini belirtmişlerdir. Sibiya ve Sumbwanyambe (2019) yılında mısır bitkisinde kuzey mısır yaprak yanıklığı, gri yaprak lekesi ve mısır pası gibi hastalıklarının tespit etmek için CNN kullanmıştır ve doğruluk oranı %92,85 olarak bulunmuştur. Shrivastava ve ark. (2019) piriç hastalığının sınıflandırılması için derin CNN'nin transfer öğrenimini kullanmışlardır ve hastalığı %91,37 doğrulukla tanımlamışlardır. Jiang ve ark. (2020) transfer öğrenimini, bitki hastalığı tanıma modeli oluşturmak için ResNet üzerine uygulayarak, transfer öğrenme modelinin hastalık tanımlama doğruluğunun %83,75 olduğunu ve bunun geleneksel ResNet-101 modelinden çok daha yüksek olduğunu ortaya koymuşlardır. Çalışma verilerine dayanarak, transfer öğrenme algoritmasına dayalı bitki hastalığı tanıma modelini son derece uygulanabilir bir çözüm olarak sunmuşlardır. Xie ve ark. (2021) çatlak, şekil bozukluğu, çatalı, kırık olan havuçları satıştan önce tespit etmek için derin öğrenme ve transfer öğrenmeye dayalı yöntemi önermiştir. Kusurlu havuçların tanınması için beş klasik CNN (Densenet-121, ResNet-50, Inception-V3, VGG-16 ve VGG-19) uygulanmıştır. Bu topluluk modellerinde ResNet-50 sabit bir model olarak seçilmiş ve diğer dört modelden herhangi ikisiyle ortalama alma yöntemiyle birleştirilmiştir. Sonuçlar ResNet-50, Densenet-121 ve VGG-16'dan (R-D-V16) oluşan topluluk modelinin sırasıyla %97,34, %99,53, %94,62, %99,62, %97,01 ve görüntü başına 0,09s doğruluk, kesinlik, duyarlılık, özgüllük, F1-skoru ve tespit hızı ile en iyi performansı gösterdiği ortaya konulmuştur.

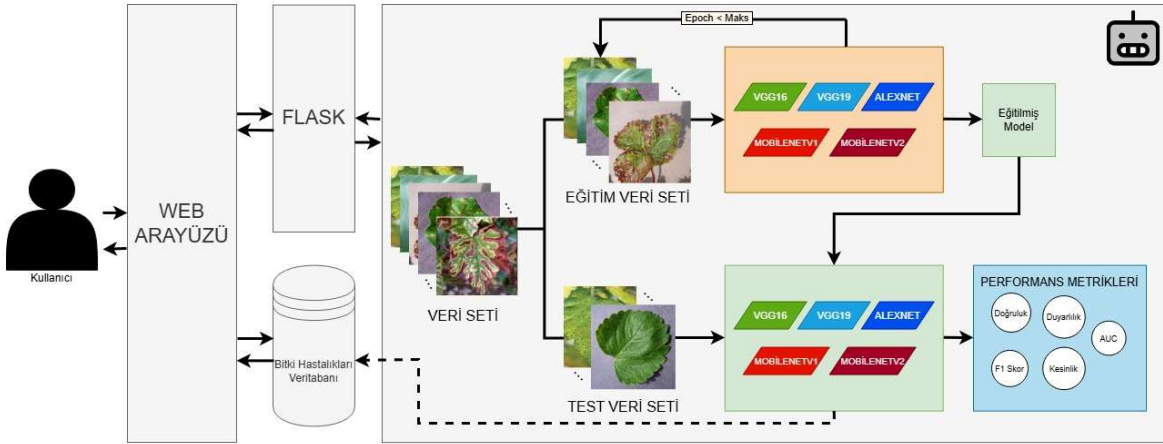
Mehedi ve ark. (2022) çeşitli bitki hastalıklarının tespit etmek için transfer öğrenme yaklaşımını, önceden eğitilmiş modeller olan EfficientNetV2L, MobileNetV2 ve ResNet152V2 ile kullanmışlardır. Çalışmada 14 farklı bitki türünde 38 çeşit yaprak hastalığını tespit etmek için, önceden eğitilmiş üç modeli çeşitli niceliksel performans değerlendirme parametrelerine göre karşılaştırarak, EfficientNetV2L modelinin %99,63 doğrulukla en iyi performansı sergilediğini belirtmişlerdir. Shahoveisi ve ark. (2023), dört evrişimli sinir ağı modelinin üç ticari açıdan önemli tarla ürününde pas hastalığının tespitindeki potansiyelini değerlendirmiş ve EfficientNetB4 modelinin doğruluk oranını ortalama %94,29 olarak bulmuşlar. Vallabhajosyula ve ark. (2024) Vision Transformer ve ResNet9 modellerini kullanan yeni bir hiyerarşik kalıntı vizyon dönüştürücüsü (Residual Vision Transformer) ile yaprak hastalıklarının erken tespitine yardımcı olan bir model ile 13, 38 ve 51 farklı yaprak hastalığı sınıfına sahip Local Crop veri seti, Plant Village veri seti ve Extended Plant Village veri seti üzerinde değerlendirilmiştir. Performans değerlendirmesi, veri setlerinde geniş kapsamda yapılmış ve sonuçlar, önerilen modelin InceptionV3, MobileNetV2 ve ResNet50 gibi diğer modellere göre daha iyi performans gösterdiğini ortaya koymuştur.

Literatürdeki bu çalışmalar göz önüne alındığında, bitki hastalıklarının sınıflandırılmasında transfer öğrenme yöntemlerinin etkin sonuçlar verdiği görülmektedir. Fakat, bitki yapraklarından hastalık sınıflandırılmasında transfer öğrenme yöntemlerinin karşılaştırmalı olarak sunulmasında sınırlılık gözlenmiştir.

## MATERYAL ve METOD

Bu çalışmada, bitki yaprak hastalıklarının tanımlanması ve sınıflandırılması için 5 farklı transfer öğrenme modelleri kullanılmıştır. Amaç, VGG16, VGG19, AlexNet, MobileNetV1 ve MobileNetV2 modellerini kullanarak

en iyi sonuçları veren algoritmayı belirlemek ve bu modellerin performansını artırmaktır. Çalışmanın genel akış diyagramı Şekil 1'de verilmiştir.



Şekil 1. Bitki yaprak hastalıklarının tespiti için Genel Akış Diyagramı  
Figure 1. The diagram of general flow for detection of plant leaf diseases

### Veri Seti

Çalışmada kullanılan ana veri setinde (Kaggle, 2020) sağlıklı ve hastalıklı bitki yapraklarının 87.867 adet görüntüsü bulunmaktadır. Fakat, veri setinde yaban mersini, ahududu ve soya fasulyesi bitkilerine ait sadece sağlıklı bitkilerin görüntüleri bulunmaktadır. Dolayısıyla veri setinde hastalıklı durumlarına ait herhangi bir görüntü bulunmadığı için veri setinden çıkarılmıştır. Ayrıca, asma siyah çürüklüğü hastalığının yaygın bulunmaması ve akarın hastalık etmeni olmaması sebebiyle domatesteki akar zararlısına ait görüntüler veri setinden kaldırılmıştır. Veri seti analizinde, uzman görüşü ile elma memeli pası hastalığına ait görüntüler ise problemi temsil kabiliyetinin sınırlı bulunması nedeniyle veri setinden çıkarılarak, yerel görüntüler ile bu sınıfa yeni görüntüler eklenmiştir. Bu işlemler sonucunda veri setinden toplam 13761 adet görüntü azalmıştır. Çalışmada bitki yaprak hastalıklarının kapsamının genişletilebilmesi için bağ antraknozu, bağ mildiyösü, bağ küllemesi, şeftali yaprak kıvrıcılığı, domates lekeli solgunluk virüsü, ceviz antraknozu ve elma memeli pası hastalıklarına ait görüntüler ile birlikte, sağlıklı portakal, kabak ve ceviz bitkilerine ait görüntülerin derlenmesi sonucunda 11.520 adet yeni görüntü ile veri seti genişletilmiştir (Hastalıklı ve sağlıklı bitki görüntüleri Kahramanmaraş Sütçü İmam Üniversitesi Ziraat Fakültesi Bitki Koruma Bölümünden temin edilmiştir). Eklenen yeni görüntüler ile çalışmada kullanılan veri setinde toplam 85.626 RGB görüntüsü bulunmaktadır. Şekil 2'de veri setinden örnek görüntüler sunulmuştur.

Veri setindeki sağlıklı bitkiler;

- Elma, kiraz, mısır, asma, portakal, şeftali, biber, patates, kabak, çilek, domates, ceviz'dir.

Veri setindeki hastalıklar;

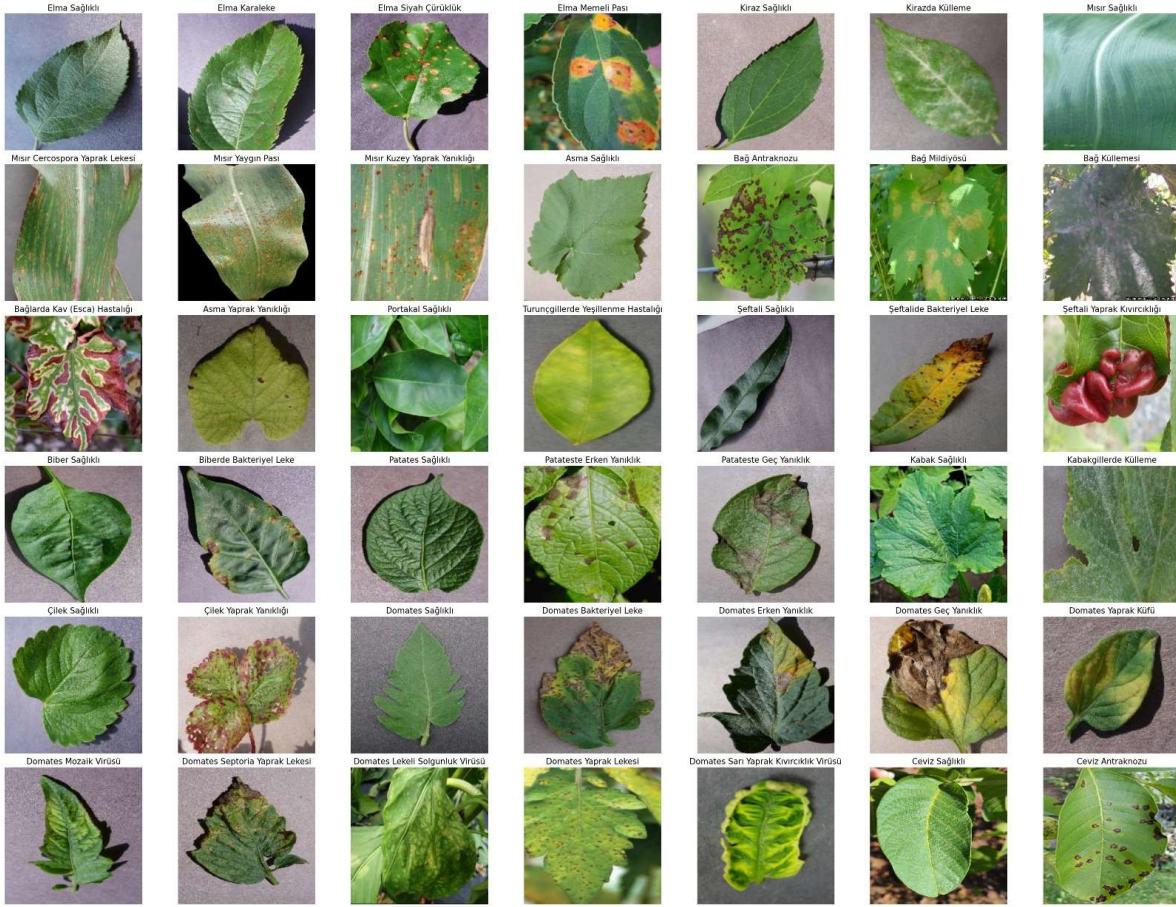
- Elma karaleke, elma siyah çürüklük, elma memeli pası, kirazda külleme, mısır cercospora yaprak lekesi, mısır yaygın pası, mısır kuzey yaprak yanıklığı, bağ antraknozu, bağ mildiyösü, bağ küllemesi, bağlarda kav (esca) hastalığı, asma yaprak yanıklığı, turunçgillerde yeşillenme hastalığı, şeftalide bakteriyel leke, şeftali yaprak kıvrıcılığı, biberde bakteriyel leke, patateste erken yanıklık, patateste geç yanıklık, kabakgillerde külleme, çilek yaprak yanıklığı, domates bakteriyel leke, domates erken yanıklık, domates geç yanıklık, domates yaprak küfü, domates mozaik virüsü, domates septoria yaprak lekesi, domates lekeli solgunluk virüsü, domates yaprak lekesi, domates sarı yaprak kıvrıcılık virüsü, ceviz antraknozu'dur.

Toplam veri seti, dizin yapısı korunarak 80/20 oranında eğitim ve test setine bölünmüştür. Eğitim setinde 68.501, test setinde 17.125 olmak üzere toplam 85.626 görüntü bulunmaktadır. Veri seti genel olarak sınıflar açısından dengeli bir veri setidir. Bitkilere göre görüntü sayıları Çizelge 1'de rapor edilmiştir.

### Veri Arttırma

Veri artırımı, modelin genelleme yeteneğini artırabilmekte ve aşırı öğrenmeyi önleyebilmek için kullanılmaktadır (Wang, 2017). Bu nedenle, modelleme süreçlerinde yaygın olarak kullanılan etkili bir yaklaşımdır (Simonyan &

Zisserman 2014). CNN yöntemlerini eğitmeye başlamadan önce veri setini çeşitlendirmek amacıyla Çalışmada veri artırımı gerçekleştirildi. Bu çalışmada kullanılan veri artırma işlemi şunlardır;



Şekil 2. Veri Setinden örnek bir görüntü kümesi  
Figure 2. A set sample images from the used dataset

- (a) **Yatay ve Dikey Çevirme (Yatay):** Giriş verilerinin yatay veya dikey olarak çevrilmesini içeren sıklıkla kullanılan veri büyütme işlemleridir. Bu, modelin eğitim veri kümesindeki nesnelerin farklı yönelimlerini öğrenmesine yardımcı olur. Ayrıca yeni verilere genelleme yeteneğini geliştirebilir.
- (b) **Genişlik Kaydırma Aralığı (0,2):** Görüntüleri yatay yönde kaydırmak için kullanılan bir aralığı belirtir. Bu değer, orijinal görüntü genişliğinin bir yüzdesi olarak ifade edilir.
- (c) **Yakınlaştırma Aralığı (0,2):** Görüntülerin yakınlaştırma veya uzaklaştırma derecesini belirler.
- (d) **Dolgu Modu (En yakın):** Görüntülerin yeniden boyutlandırılması, döndürülmesi ya da kırılması gibi işlemler sırasında oluşabilecek boşlukları nasıl doldurulacağını belirtir. “En yakın” parametresi ise bu boşlukları en yakın piksel ile doldurulmasını sağlar.
- (e) **Doğrulama Ayrımı (0,2):** Verilerin eğitim ve doğrulama setlerine nasıl bölüneceğini belirten bir parametredir. Bu parametre, verilerin belirli bir oranının doğrulama seti olarak ayrılacağını belirtir.
- (f) **Yeniden Ölçekleme (1/255):** Görüntülerin yeniden ölçeklendirilmesi işlemi sırasında kullanılır. Bu parametre, görüntüdeki piksel değerlerini yeniden ölçeklendirerek 0 ile 1 arasında düzenlenmesini sağlar. İşlemin amacı, modelin daha iyi öğrenebilmesi için veri setini uygun bir ölçeğe getirmektir.
- (g) **Rastgele Rotasyon (90°):** Giriş verilerinin rastgele bir açıyla döndürülmesini içeren yaygın bir veri büyütme işlemidir. Bu, modelin eğitim veri kümesindeki nesnelerin farklı yönelimlerini öğrenmesine yardımcı olur.

## VGG16

VGG16 (Karen ve ark., 2014), genel olarak görsel sınıflandırma görevlerinde kullanılmak üzere tasarlanmış derin bir evrişimli sinir ağıdır. VGG16'nın önemli özelliklerinden biri, basit ve tutarlı bir mimariye sahip olmasıdır. Model, ardışık bir dizi evrişim katmanından oluşur. Bu katmanlar, görsel özellikleri çıkarmak için filtreleri kullanır. Her evrişim katmanının çıkışında genellikle ReLU gibi doğrusal olmayan aktivasyon fonksiyonları

uygulanır. Evrişim katmanlarından sonra havuzlama katmanları gelir. Bu katmanlar, özellik haritasını küçültmek ve öğrenilen özellikleri özetlemek amacıyla kullanılır. Modelin çıkışında genellikle softmax aktivasyon fonksiyonu kullanılır.

Bu projede VGG16 modeli farklı batch boyutu ve epoch değerleri üzerinde eğitilmiş ve başarı oranı ortalama olarak %90 elde edilmiştir. Modelleme de elde edilen doğruluk ve kayıp grafiği Çizelge 3'de sunulmuştur.

#### Çizelge 1. Veri Seti Dağılımı

Table 1. Data Set Distribution

Sınıf İsimleri	Sayı
Elma Sağlıklı	2510
Elma Karaleke	2520
Elma Siyah Çürüklük	2483
Elma Memeli Pası	1020
Kiraz Sağlıklı	2282
Kirazda Külleme	2104
Mısır Sağlıklı	2324
Mısır Cercospora Yaprak Lekesi	2052
Mısır Yaygın Pası	2384
Mısır Kuzey Yaprak Yanıklığı	2385
Asma Sağlıklı	2115
Bağ Antraknozu	980
Bağ Mildiyösü	960
Bağ Küllemesi	1020
Bağlarda Kav (Esca) Hastalığı	2400
Asma Yaprak Yanıklığı	2152
Portakal Sağlıklı	1300
Turunçgillerde Yeşillenme Hastalığı	2513
Şeftali Sağlıklı	2160
Şeftalide Bakteriyel Leke	2297
Şeftali Yaprak Kıvrıcıklığı	1100
Biber Sağlıklı	2485
Domates Lekeli Solgunluk Virüsü	1740
Patates Sağlıklı	2280
Patateste Erken Yanıklık	2424
Patateste Geç Yanıklık	2424
Kabak Sağlıklı	1060
Kabakgillerde Külleme	2170
Çilek Sağlıklı	2280
Çilek Yaprak Yanıklığı	2218
Domates Sağlıklı	2407
Domates Bakteriyel Leke	2127
Domates Erken Yanıklık	2400
Domates Geç Yanıklık	2314
Domates Yaprak Küfü	2352
Domates Mozaik Virüsü	2238
Domates Septoria Yaprak Lekesi	2181
Domates Yaprak Lekesi	2284
Domates Sarı Yaprak Kıvrıcıklık Virüsü	2450
Ceviz Sağlıklı	1260
Ceviz Antraknozu	1080

#### Çizelge 2. Eğitim Modellerinde Kullanılan Batch Boyutu ve Epoch Sayıları

Table 2. Batch Sizes and Number of Epochs Used in Training Models

Model	Batch Boyutu	Epoch
M1	32	10
M2	20	10
M3	20	40

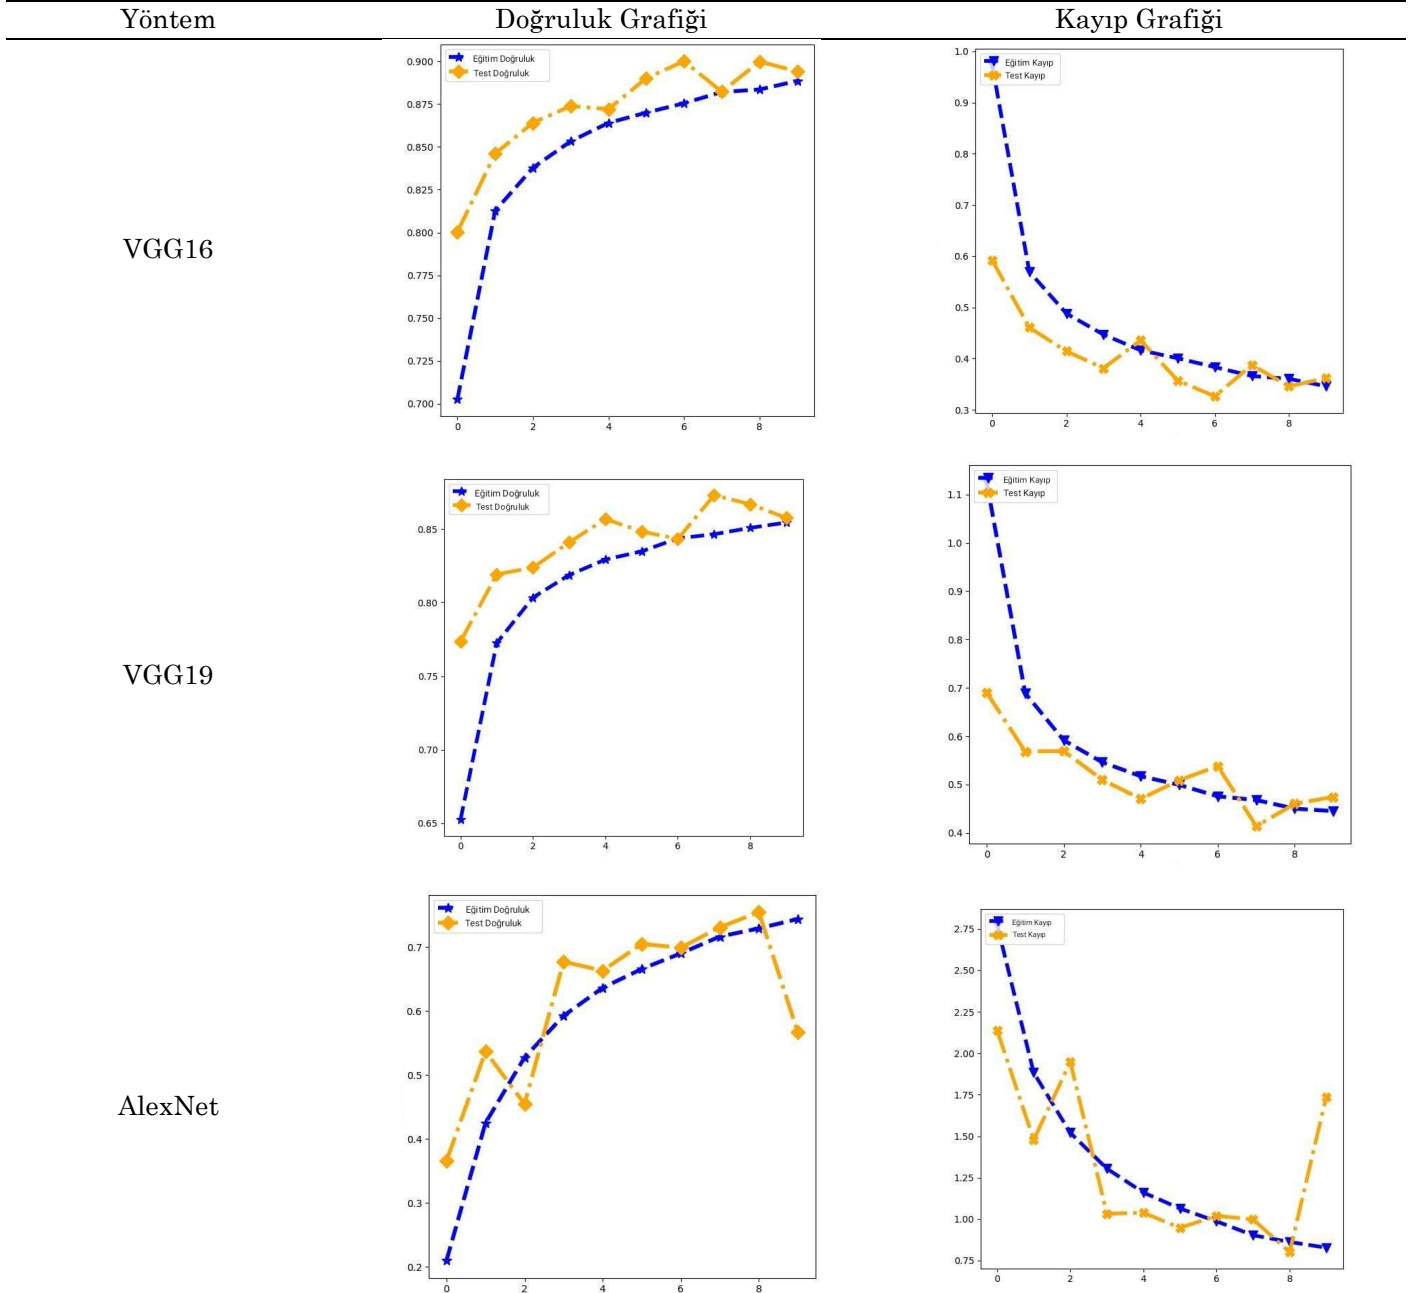
### VGG19

VGG19 (Karen ve ark., 2014), Oxford Üniversitesi'nde yer alan Visual Geometry Group (VGG) tarafından geliştirilmiş bir evrişimli sinir ağı mimarisidir. VGG16'nın genişletilmiş bir sürümüdür. Daha derin bir yapıya sahiptir. VGG modelleri, büyük veri setlerinde öğrenme kapasitesi ve genelleme yeteneğiyle tanınan derin öğrenme modelleridir. VGG19, VGG16'nın daha kompleks bir versiyonudur. Bu nedenle daha fazla parametreye sahiptir. Bu sayede daha karmaşık görevlerde daha iyi performans elde etme potansiyeli sağlamaktadır. Ancak daha fazla hesaplama gücü ve veri seti gerektirebilir.



Çalışmada VGG19 modeli farklı batch boyutu ve epoch değerleri üzerinde eğitilmiş ve başarı oranı ortalama %86 olarak elde edilmiştir. Modelleme de elde edilen doğruluk ve kayıp grafiği Çizelge 3'de sunulmuştur.

Çizelge 3. Transfer Öğrenme yöntemlerinin doğruluk ve kayıp grafikleri



Table 3. The Accuracy and loss graphs of transfer learning methods



### MobileNetV2



### MobileNetV1



### AlexNet

AlexNet (Krizhevsky, 2012), 2012 yılında ImageNet Large Scale Visual Recognition Challenge yarışmasında büyük bir başarı elde ederek derin öğrenme alanında öne çıkmıştır. Modelin önemli özelliklerinden biri, o döneme kadar yapılmış en başarılı derin sinir ağı olmasıdır. AlexNet 8 evrişim ve 3 tam bağlantılı katman içermektedir. Evrişim katmanları, giriş görüntülerindeki özellikleri öğrenmek için ReLU aktivasyon fonksiyonlarıyla birlikte kullanılmaktadır. Ardından, özellik haritalarını küçültmek ve özetlemek için maksimum havuzlama katmanları gelmektedir. Ayrıca, aşırı öğrenmeyi azaltmak için dropout ve veri artırımı gibi teknikler uygulanmaktadır.

Bu çalışmada AlexNet modeli farklı batch boyutu ve epoch değerleri üzerinde eğitilmiş ve diğer modellere göre daha düşük başarı oranı vermiştir. Başarı oranı ortalama olarak %73 elde edilmiştir. Modelleme de elde edilen doğruluk ve kayıp grafiği Çizelge 3'de sunulmuştur.

### MobileNetV2


MobileNetV2 (Sandler ve ark., 2018), hesaplama maliyeti düşük ve etkili bir evrişimli sinir ağı (CNN) mimarisidir. Genellikle mobil cihazlarda veya kaynak sınırlı ortamlarda kullanılmak üzere tasarlanmıştır. Bu mimari, önceki MobileNet modellerinin geliştirilmiş bir versiyonudur. Çeşitli uygulamalarda düşük hesaplama maliyeti ile iyi performans sağlamayı amaçlar. MobileNetV2'de temel yapı Ters Çevrilmiş Artık Blok (Inverted Residual Block) olarak adlandırılır. Bu çalışmada MobileNetV2 modeli farklı batch boyutu ve epoch değerleri üzerinde eğitilmiş ve başarı oranı ortalama olarak %93 elde edilmiştir. Modelleme de elde edilen doğruluk ve kayıp grafiği Çizelge 3'de sunulmuştur.

### MobileNetV1

MobileNetV1 (Howard ve ark., 2017), Google tarafından geliştirilen ve özellikle düşük güç tüketimli derin öğrenme modeli mimarisidir. MobileNetV1'in mimarisi Şekil 3'de sunulmuştur. Bu mimari, bilgisayar görüşü görevlerini yerine getirmek üzere tasarlanmış olup, mobil uygulamalarda gerçek zamanlı olarak çalışabilecek hızda ve etkili bir şekilde performans göstermeyi hedefler. MobileNetV1'in en belirgin özelliği, geleneksel evrişim katmanlarını daha verimli hale getirmek için Derinlemesine Ayrılabilir Evrişim (Depthwise Separable Convolution) tekniğini kullanmasıdır.



Bu çalışmada MobileNetV1 modeli farklı batch boyutu ve epoch değerleri üzerinde eğitilmiş ve başarı oranı diğer modellere göre daha yüksek bir sonuç vermiştir. Başarı oranı ortalama olarak %97 elde edilmiştir. Modelleme de elde edilen doğruluk ve kayıp grafiği Çizelge 3'de sunulmuştur.



Şekil 3. MobileNetV1 Mimarisi  
Figure 3. MobileNetV1 Architectural

### Web Entegrasyonu

MobileNetV1 modeli, bitki hastalıkları tespiti için geliştirilen web sitesi uygulamasında kullanılmak üzere .h5 uzantılı dosya formatında kaydedildi. Modelin .h5 formatında kaydedilmesi, web sitesi uygulamasına entegrasyon sürecini kolaylaştırmaktadır. Bu entegrasyon, hızlı ve etkili web uygulamaları geliştirmek için ideal bir framework olan Flask (Vangala ve ark., 2019) ile Visual Studio (Microsoft, 2024) kullanılarak gerçekleştirilmiştir.

Web uygulaması, kullanıcıların bitki yaprağı görüntülerini yükleyebileceği ve bu görüntülerin işlenerek hastalık tespitinin yapılacağı bir platform sağlar. Kullanıcılar, web sitesinde bulunan dosya yükleme formunu kullanarak bitki yaprağı görüntülerini yükleyebilirler. Bu form, kullanıcıların sunucuya dosya yüklemesini sağlar. Form etiketi içindeki method="post" ve action="/file-upload" özellikleri, formun HTTP POST yöntemiyle gönderileceğini ve gönderilen verilerin /file-upload adresine yönlendirileceğini belirtir. Bu işlem, @app.route('/file-upload', methods=['POST']) rotası ile yönetilir. Bu rota, kullanıcıların yüklediği görüntülerin sunucuya gönderilmesini ve işlenmesini sağlar.

HTTP isteği ile yüklenen bitki yaprağı dosyası alınır ve Pillow kütüphanesi kullanılarak bir görüntüye dönüştürülür. Pillow (Clark ve ark), güçlü bir görüntü işleme kütüphanesidir. Python'da görüntülerle çalışmayı kolaylaştırmaktadır. Görüntü, modelin gereksinimlerine uygun olarak 224x224 piksel boyutlarına yeniden boyutlandırılır. Bu, çoğu derin öğrenme modelinin girdi olarak beklediği boyuttur.

Daha sonra, görüntü verisi normalleştirilir. Normalleştirme, piksel değerlerini [0, 1] aralığına ölçeklendirerek görüntü işleme işlemini standardize edilmektedir. Bu işlem modelin daha tutarlı sonuçlar üretmesine yardımcı olabilir. Normalleştirilmiş görüntü verisi, modelin işleyebileceği bir diziye dönüştürülür. Genellikle, modelin beklediği formata uygun hale getirmek için görüntüye bir dizi ek boyut eklenir.

Model, `model.predict(img array)` komutu ile görüntüyü sınıflandırır ve sonuçlar, sınıflandırma doğruluğu açısından en yüksek olasılığa sahip sınıf belirlenerek elde edilir. Bu sonuç, ilgili hastalık veya sağlıklı durum ile eşleştirilir.

### BULGULAR ve TARTIŞMA

Eğitim sürecinde optimize edilen parametreler, öğrenme oranı, epoch sayısı ve batch boyutu, model performansını artırmada etkili olmuştur. Modellerin performansını değerlendirebilmek için farklı epoch ve batch boyutları için eğitim işlemi gerçekleştirilmiştir. Tanımlanan eğitim modelleri Çizelge 2'de sunulmuştur.

M1 modeli üzerinden elde edilen deneysel sonuçlar Çizelge 4'de, M2 modeli üzerinden elde edilen sonuçlar Çizelge 5'de ve M3 modeli üzerinden elde edilen sonuçlar ise Çizelge 6'de rapor edilmiştir. Transfer öğrenme yöntemleri bu parametre değerleri kullanılarak model doğrulukları karşılaştırılmıştır. Çizelge 4, Çizelge 5 ve Çizelge 6 incelendiğinde, M3 modeli MobileNetV1 algoritması bitki hastalıklarını tespit etmede %99,20 başarı ile en iyi sonuç veren algoritma olduğu sonucuna ulaşılmıştır.

Transfer öğrenme yöntemlerinin modelleme süreçlerinde ki performanslarının değerlendirilebilmesi için M2 modeli üzerinden doğruluk ve kayıp grafikleri Çizelge 3'de sunulmuştur. Modelleme grafikleri incelendiğinde aşırı

öğrenme problemi ile karşılaşılmadığı görülmektedir. Bu bulgu, deneysel sonuçlar üzerinden gerçek-zamanlı uygulamada arzu edilen sonuçların elde edilebileceğini göstermektedir.

Çizelge 4. M1 modeli üzerinden elde edilen sonuçlar  
*Table 4. Obtained results on the M1 model*

	Kayıp	Doğruluk	Doğrulama Kaybı	Doğrulama Doğruluğu
VGG16	0,2989	0,9021	0,3155	0,9081
VGG19	0,3796	0,8753	0,4579	0,8671
AlexNet	0,6202	0,8045	0,8411	0,7651
MobileNetV1	0,0464	<b>0,9850</b>	0,1108	0,9679
MobileNetV2	0,0617	0,9800	0,1808	0,9484

Çizelge 5. M2 modeli üzerinden elde edilen sonuçlar  
*Table 5. Obtained results on the M2 model*

	Kayıp	Doğruluk	Doğrulama Kaybı	Doğrulama Doğruluğu
VGG16	0,3410	0,8895	0,3619	0,8941
VGG19	0,4411	0,8555	0,4745	0,8575
AlexNet	0,8224	0,7437	1,7370	0,5664
MobileNetV1	0,0593	<b>0,9801</b>	0,0679	0,9814
MobileNetV2	0,0789	0,9750	0,4788	0,8888

Çizelge 6. M3 modeli üzerinden elde edilen sonuçlar  
*Table 6. Obtained results on the M3*

	Kayıp	Doğruluk	Doğrulama Kaybı	Doğrulama Doğruluğu
VGG16	0,2626	0,9183	0,4072	0,9036
VGG19	0,3612	0,8877	0,4193	0,8862
AlexNet	0,5372	0,8434	0,5127	0,8666
MobileNetV1	0,0160	<b>0,9948</b>	0,0271	0,9920
MobileNetV2	0,0226	0,9929	0,0767	0,9795


Bitki hastalıklarının tespit edilmesinde en yüksek doğruluğu veren MobileNetV1 M3 modeli olduğunda modelinin performansının detaylı değerlendirilebilmesi için doğruluk ve kayıp grafikleri Şekil 4'de sunulmuştur. Makine öğrenmesinde sıklıkla kullanılan modelin sınıflandırma performansını değerlendirmek için ROC eğrisi analizi de yapılmıştır. ROC eğrisi, doğru pozitif oranını (TPR) yanlış pozitif oranına (FPR) karşı çizer ve modelin farklı eşik değerlerindeki performansını gösterir. Grafikte her bir sınıf için ayrı bir ROC eğrisi çizilmiş ve tüm sınıflar için AUC değerleri hesaplanmıştır. AUC'nin 1.0 olması, modelinin sınıflar için etkin bir performans sergilediğini ve doğru sınıflandırma yaptığını göstermektedir. Elde edilen ROC grafiği Şekil 5'de sunulmuştur. Ayrıca, karmaşıklık matrisi ise Şekil 6'da sunulmuştur.

Şekil 4 incelendiğinde, aşırı öğrenme sorunu bulunmadığı görülmektedir. Şekil 6'da sunulan karmaşıklık matrisi incelendiğinde ise modelin 42 farklı bitki hastalığı ve sağlıklı durum sınıflarını sınıflandırma etkin ve kararlı bir yöntem olduğu görülmektedir.

Makine Öğrenmesi modellerinin değerlendirilmesinde doğruluk haricinde Kesinlik (Precision), Duyarlılık (Sensitivity) ve F1 skoru metrikleri de kullanılmaktadır. Kesinlik metriği pozitif etiketlerine sahip etiketlerinin pozitif olarak bulunabilme oranı olarak tanımlanmaktadır. Duyarlılık ise modelin pozitif örneklerin ne kadarını pozitif olarak tahmin etmen oranına karşılık gelmektedir. F1 skoru ise kesinlik ve duyarlılık oranlarının harmonik ortalaması olarak hesaplanır. Çizelge 7'de MobilNetV1 için Kesinlik, Duyarlılık ve F1 skoru sonuçları her bir sınıf için sunulmuştur. Çizelge 7 incelendiğinde önerilen model Kesinlik için en düşük 0,92 oranına sahipken, Duyarlılık için en düşük 0,94 oranına sahiptir. F1 skoru için ise en düşük oran 0,96'dır. Kesinlik, Duyarlılık ve F1 skor metrikleri için en yüksek oran 1,00 olarak hesaplanmıştır. Çizelge 7 genel olarak değerlendirildiğinde, önerilen yöntem ile her bir sınıfın diğer sınıflara göre oldukça ayrıştırılabilir olduğu görülmektedir.

Elde edilen bulgular genel olarak değerlendirildiği de önerilen yöntemin bitki yaprak hastalıklarının sınıflandırılmasında %99,2 ile mükemmel yakın doğruluk gösterdiği görülmektedir. Fakat, bu sonuçların literatürde daha önce yayınlanan diğer çalışmalar ile adil bir karşılaştırma yapılabilmesi adına temel veri setinin kullanıldığı çalışmalar derlenmiş ve Çizelge 8'de karşılaştırmalı olarak rapor edilmiştir. Çizelge 8 incelendiğinde ResNet, DenseNet ve Özel CNN modellerinin kullanıldığı görülmektedir. Önerilen yöntem ile %99,2 doğruluk oranı ile rakip yöntemlerden daha başarılı sonuçlar alındığı görülmektedir. (Chohan ve ark., 2020) tarafından gerçekleştirilen çalışmada CNN modeli %98,3 doğruluk değeri edilmiştir. (Chellapandi ve ark., 2021) tarafından


yürütülen bir diğer çalışmada ise %99 doğruluk oranı elde edilmiştir. Bu iki çalışma önerilen yöntemden nispeten geride kalmıştır. Önerilen yöntem diğer rakiplerden ise görece daha başarılıdır.



(a) Doğruluk

(b) Kayıp

Şekil 4. MobileNetV1 M3 modeli üzerinden elde edilen Doğruluk(a) ve Kayıp Grafiği(b)  
Figure 4. MobileNetV1 obtained Accuracy (a) and Loss Graph (b) on the M3 model



Şekil 5. AUC – ROC Eğrisi Sonuçları  
Figure 5. AUC – ROC Curve Results



sunmaktadır. Böylece, hastalıkların erken teşhisi ve uygun tedavi yöntemlerinin uygulanması mümkün olur, tarımsal verimlilik artacağı ön görülmektedir.

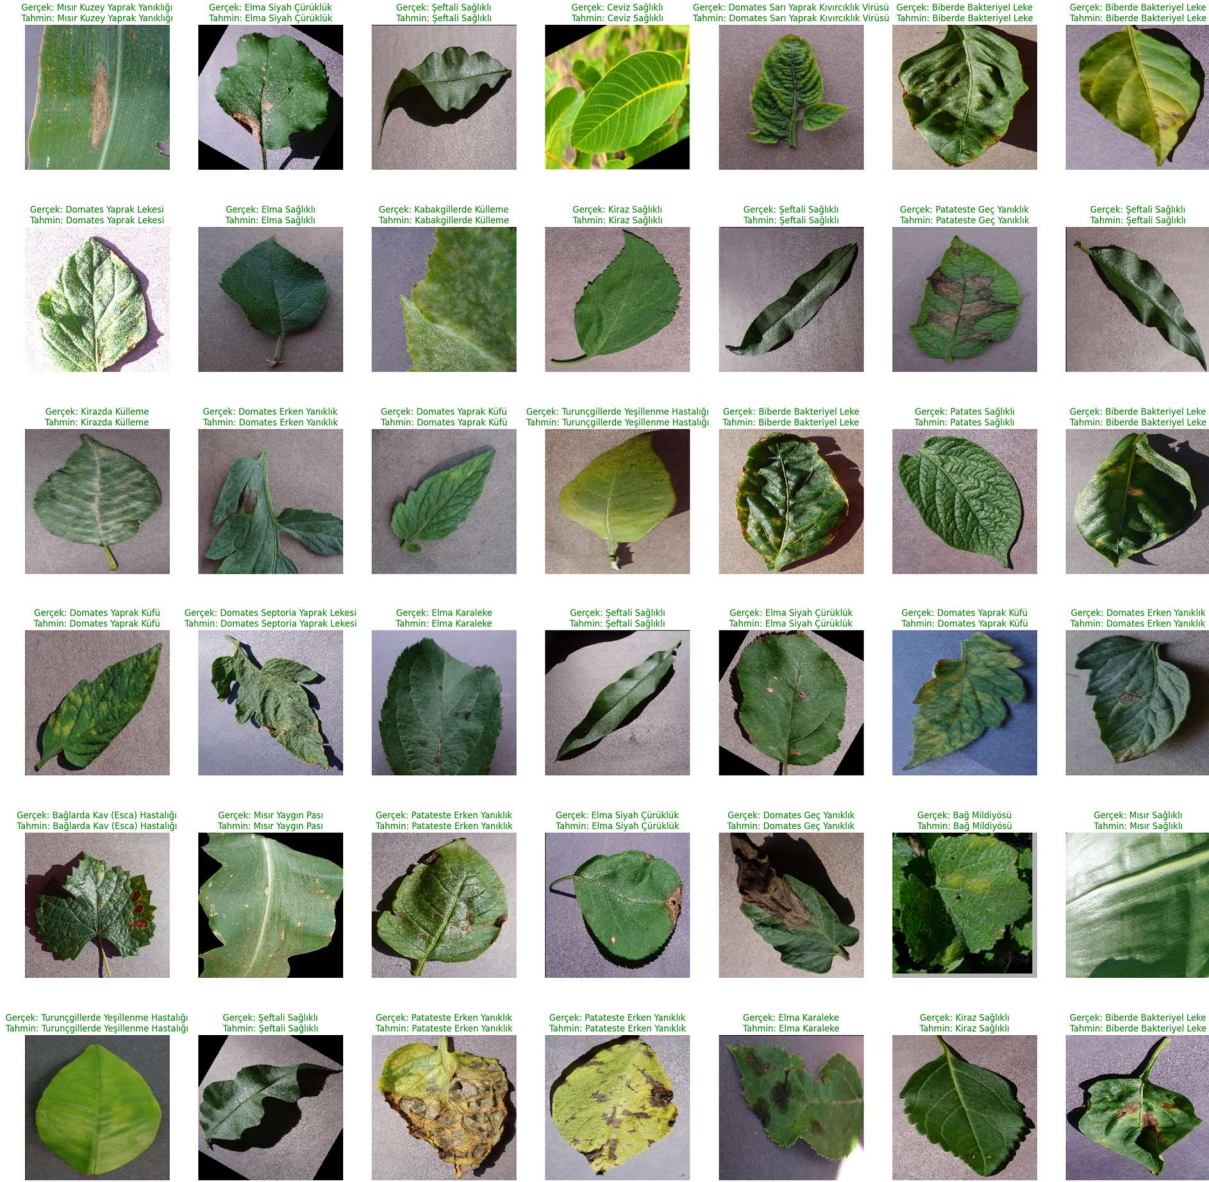
Çizelge 7. MobileNetV1 için M3 modeli üzerinden Kesinlik, Duyarlılık ve F1-Skor Sonuçları  
*Table 7. The Results of Precision, Sensitivity, and F1-Score for MobileNetV1 on the M3*

	Kesinlik	Duyarlılık	F1- Skoru
Elma Sağlıklı	1,00	1,00	1,00
Elma Karaleke	1,00	1,00	1,00
Elma Siyah Çürüklük	1,00	1,00	1,00
Elma Memeli Pası	1,00	0,98	0,99
Kiraz Sağlıklı	1,00	1,00	1,00
Kirazda Külleme	1,00	1,00	1,00
Mısır Sağlıklı	1,00	1,00	1,00
Mısır Cercospora Yaprak Lekesi	0,99	0,94	0,97
Mısır Yaygın Pası	0,99	1,00	0,99
Mısır Kuzey Yaprak Yanıklığı	0,95	1,00	0,97
Asma Sağlıklı	1,00	1,00	1,00
Bağ Antraknozu	0,96	0,98	0,97
Bağ Mildiyösü	0,96	0,99	0,98
Bağ Küllemesi	1,00	0,99	0,99
Bağlarda Kav (Esca) Hastalığı	1,00	1,00	1,00
Asma Yaprak Yanıklığı	1,00	1,00	1,00
Portakal Sağlıklı	0,99	1,00	0,99
Turunçgillerde Yeşillenme Hastalığı	1,00	0,99	0,99
Şeftali Sağlıklı	1,00	0,97	0,99
Şeftalide Bakteriyel Leke	0,97	1,00	0,98
Şeftali Yaprak Kıvrıcıklığı	1,00	0,98	0,99
Biber Sağlıklı	0,98	1,00	0,99
Biberde Bakteriyel Leke	0,99	1,00	1,00
Patates Sağlıklı	1,00	0,99	0,99
Patateste Erken Yanıklık	1,00	1,00	1,00
Patateste Geç Yanıklık	1,00	0,99	0,99
Kabak Sağlıklı	1,00	0,96	0,98
Kabakgillerde Külleme	1,00	1,00	1,00
Çilek Sağlıklı	1,00	1,00	1,00
Çilek Yaprak Yanıklığı	1,00	1,00	1,00
Domates Sağlıklı	1,00	1,00	1,00
Domates Bakteriyel Leke	1,00	0,99	1,00
Domates Erken Yanıklık	0,99	0,98	0,99
Domates Geç Yanıklık	0,98	0,98	0,98
Domates Yaprak Küfü	1,00	1,00	1,00
Domates Mozaik Virüsü	1,00	1,00	1,00
Domates Septoria Yaprak Lekesi	1,00	1,00	1,00
Domates Lekeli Solgunluk Virüsü	0,98	0,99	0,99
Domates Yaprak Lekesi	0,97	1,00	0,99
Domates Sarı Yaprak Kıvrıcıklık Virüsü	1,00	1,00	1,00
Ceviz Sağlıklı	1,00	0,98	0,96
Ceviz Antraknozu	0,92	1,00	0,96

Çizelge 8. Önerilen Yöntemin, önceki çalışmalar ile karşılaştırılması

*Table 8. Comparison of the Proposed Method with previously proposed methods*

Referans	Metod	Doğruluk Skoru
(Rao ve ark., 2022)	Bi-CNN	%94,98
(Geetharamani ve Pandian, 2019)	CNN	% 96,46
(Chohan ve ark., 2020)	CNN	% 98,3
(Sagar ve Jacob, 2021)	ResNet50	% 98,2
(Chellapandi ve ark., 2021)	DenseNet	%99
Önerilen Yöntem	MobileNetV1	<b>% 99,20</b>



Şekil 7. Önerilen Yöntemin Tahmin Sonuçları  
Figure 7. Prediction Results of Proposed Method.



Şekil 8. Veri Setinde Olmayan Resimlerin Test Sonuçları  
Figure 8. The results of testing Images not included in the Data Set



Şekil 9. Bitki Resim Yükleme Formu  
Figure 9. Plant Image Upload Form



Şekil 10. Hastalıklı Bitki Sonucu  
Figure 10. Diseased Plant Result Screen



Şekil 11. Sağlıklı Bitki Sonuç Ekranı  
Figure 11. Healthy Plant Result Screen

## SONUÇ ve ÖNERİLER

Bitki hastalıklarının tespiti için geliştirilen yapay zeka modeli, yüksek işlem hızı ve sınıflandırma doğruluğu sağlamaktadır. Bu çözüm, bitki yapraklarının hastalıklı mı yoksa sağlıklı mı olduğunu hızlı ve etkili bir şekilde belirleyebilir, böylece bitki hastalıklarının erken teşhis edilmesine ve tedavi edilmesine olanak tanır. Ayrıca, kullanım kolaylığı ve sonuçlara hızlı erişim imkanı sunarak, çiftçilerin ve bitki uzmanlarının uygulamalarında verimliliği arttırabilir. Bu amaç için literatür de yaygın kullanıma sahip VGG16, VGG19, AlexNet, MobileNetV1 ve MobileNetV2 yöntemleri transfer öğrenme modeli olarak kullanılmıştır. MobileNetV1 en başarılı yöntem olduğu görülmüştür. Modelleme sonucunda etkin olan MobileNetV1 üzerinden son kullanıcı için web uygulaması geliştirilmiştir.

Geliştirilen web uygulaması, bitki hastalıklarının tespitinde çiftçilere ve bitki uzmanlarına büyük kolaylık sağlayacaktır. Uygulamanın sağladığı hızlı ve doğru sonuçlar, tarımsal verimliliği artırarak ekonomik kazançların artmasına katkıda bulunur. Gelecekte, daha yüksek epoch sayıları kullanılarak modelin doğruluğu artırılabilir ve veri seti daha fazla bitki türü ve hastalığını kapsayacak şekilde geliştirilebilir. Ayrıca, bulanık derin sinir ağları ve dikkat tabanlı derin öğrenme modellerinin kullanımıyla daha yenilikçi çalışmalar yapılabilir. Bu tür yaklaşımlar, daha kapsamlı ve etkili uygulamalar sunarak tarım sektöründe önemli ilerlemeler sağlayabilir ve yenilikçi çözümlerin öncüsü olabilir.

## Araştırmacıların Katkı Oranı Beyanı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan ederler.

## Çıkar Çatışması Beyanı

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

## KAYNAKLAR

- Abade, A., Ferreira, P. A. & Vidal, F. de B. (2021). *Plant disease recognition on images using convolutional Neural networks: A systematic review. Comput. Electron. Agric., 185*, 106125. DOI: 10.1016/j.compag.2021.106125
- Bastiaans, L. (1991). *The ratio between virtual and visual lesion size as a measure to describe reduction in leaf photosynthesis of rice due to leaf blast. Phytopathology, 81*, 611-615.
- Chellapandi, B., Vijayalakshmi, M., & Chopra, S. (2021). "Comparison of Pre-Trained Models Using Transfer Learning for Detecting Plant Disease", 2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS), Greater Noida, India, 2021, pp. 383-387, DOI: 10.1109/ICCCIS51004.2021.9397098
- Chen, J., Chen, J., Zhang, D., Sun, Y., & Nanekaran, Y. A. (2020). *Using deep transfer learning for image-based plant disease identification. Computers and Electronics in Agriculture, 173*, 105393. DOI: 10.1016/j.compag.2020.105393
- Chohan, M., Khan, A., Chohan, R., Katpar, S. H., & Mahar, M. S. (2020). *Plant disease detection using deep learning. Int. J. Recent Technol. Eng., 9(1)*, 909-914. DOI: 10.35940/ijrte.A2139.059120
- Chouhan, S.S., Singh, U.P., & Jain, S. (2019). Applications of Computer Vision in Plant Pathology: A Survey. *Archives of Computational Methods in Engineering 27*, 611-632. DOI: 10.1007/s11831-019-09324-0
- Clark, A., & The Pillow Developers. *Pillow Documentation*. Python Imaging Library, 2024. <https://python-pillow.org/>
- Cruz, A.C., Luvisi, A., De Bellis, L. & Ampatzidis, Y. (2017). *Vision-based plant disease detection system using transfer and deep learning. Proceedings of the ASABE Annual International Meeting*, Spokane, WA, USA, 16-19 July. DOI: 10.13031/aim.201700241

- Dawei, W., Limiao, D., Jiangong, N., Jiyue, G., Hongfei, Z., & Zhongzhi, H. (2019). *Recognition pest by image-based transfer learning. Journal of the Science of Food and Agriculture*, 99, 4524–4531. DOI: 10.1002/jsfa.9689
- Erdoğan, C. (2024). *Türkiye’de ve Dünya’da Bitki Koruma Ürünlerinin Kullanımının Değerlendirilmesi ve Öneriler*. KSU Tarım ve Doğa Dergisi, 27(2), 382-392. DOI: 10.18016/ksutarimdog.vi.1402605
- Espejo-Garcia, B., Mylonas, N., Athanasakos, L., Vali, E. & Fountas, S. (2021). Combining generative adversarial networks and agricultural transfer learning for weeds identification. *Biosystems Engineering*, 203, 79–89. DOI: 10.1016/j.biosystemseng.2021.01.014
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. DOI: 10.1016/j.compag.2018.01.009
- Geetharamani, G., & Arun Pandian, J. (2019). *Computers Electrical Engineering*. 323–338. DOI: 10.1016/j.compeleceng.2019.04.011
- Harakannanavar, S.S., Rudagi, J.M., Puranikmath, V.I., Siddiqua, A. ve Pramodhini, R. (2022). Plant leaf diseasedetection using computer vision and machine learning algorithms. *Global Transitions Proceedings*, 3.1, 305–310. DOI: 10.1016/j.glt.2022.03.016
- Heltin Genitha, C., Dhinesh, E., & Jagan, A. (2019). Detection of leaf disease using principal component analysisand linear support vector machine. In: *Advances in Computing: Proceedings of the International Conference on Advanced Computing (ICoAC)*. DOI: 10.1109/ICoAC48765.2019.246866
- Howard, A. G., Sandler, M., Chu, G., Chen, L. H., Chen, W., & Tan, M. (2017). *MobileNets: Efficient convolutional neural networks for mobile vision applications*. arXiv preprint arXiv:1704.04861.
- Ibarra-Pérez, T., Jaramillo-Martínez, R., Correa-Aguado, H. C., Ndjatchi, C., Martínez-Blanco, M. del R., Guerrero-Osuna, H. A., Mirelez-Delgado, F. D., Casas-Flores, J. I. & Reveles-Martínez, R. (2024). A performance comparison of CNN models for bean phenology classification using transfer learning techniques. *AgriEngineering*, 6(1), 841-857. DOI: 10.3390/agriengineering6010048
- Jiang, H., Xue, Z.P. &Yan Guo (2020). Research on Plant Leaf Disease Identification Based on Transfer Learning Algorithm. *Journal of Physics: Conference Series*, 1576 012023. DOI: 10.1088/1742-6596/1576/1/012023
- Kaggle (2020). New Plant Diseases Dataset. *Kaggle Dataset*. <https://www.kaggle.com/vipooool/newplant-diseases-dataset>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). “ImageNet Classification with Deep Convolutional Neural Networks.” In: *Advances in Neural Information Processing Systems*. DOI: 10.1145/3065386
- Lopes, D.B. & Berger, R.D. (2001). The effects of rust and anthracnose on the photosynthetic competence of diseased bean leaves. *Phytopathology*, 91, 212-220. DOI: 10.1094/PHYTO.2001.91.2.212
- Luckey, A. (2012). Assessing youth perceptions and knowledge of agriculture: The impact of participating in an agventure program.
- Marzougui, M. E., Elleuch, M., & Kherallah, M. (2020). A deep CNN approach for plant disease detection. In: *2020 21st International Arab Conference on Information Technology (ACIT)*, 1–6. DOI: 10.1109/ACIT50332.2020.9300072
- Mehedi, M.H.K., Salman Hosain, A.K.M., Ahmed, S., Promita, S.T., Muna, R.K. & Hasan, M. (2022). *Plant Leaf Disease Detection using Transfer Learning and Explainable AI*. IEEE 13th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), Vancouver, BC, Canada, 2022, pp. 0166-0170, DOI: 10.1109/IEMCON56893.2022.9946513
- Microsoft. (2024). *Visual Studio Code*. Retrieved from <https://code.visualstudio.com/>
- Mohanty, S.P., Hughes, D.P. & Salathe, M. (2016). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7, 1419-1419. DOI: 10.3389/fpls.2016.01419
- Murk, C., Khan, A., Katper, S. H., Mahar, M. S. & Bhutto, B. N. (2020). Plant Disease Detection using Deep Learning. *International Journal of Recent Technology and Engineering (IJRTE)*, 8(4), 1621-1625. DOI: 10.35940/ijrte.A2139.059120
- Nachtigall, L. G., Araujo, R. M. & Nachtigall, G. R. (2016). Classification of apple tree disorders using convolutional neural networks. In: *Proceedings of the 2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI)*, San Jose, CA, USA, 6–8 November 2016; pp. 472–476. DOI: 10.1109/ICTAI.2016.0078
- Nigam, S., Jain, R., Marwaha, S., Arora, A., Haque, M. A., Dheeraj, A. & Singh, V. K. (2023). Deep transfer learning model for disease identification in wheat crop. *Ecological Informatics*, 75, 102068. DOI: 10.1016/j.ecoinf.2023.102068
- Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., & Johannes, A. (2019). Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild. *Computers and Electronics in Agriculture*, 161, 280–290. DOI: 10.1016/j.compag.2018.04.002
- Rajasekaran, C., Arul, S., Devi, S., Gowtham, G. & Jeyaram, S. (2020). Turmeric plant diseases detection and classification using artificial intelligence. *International Conference on Signal Processing and Communication*. DOI: 10.1109/ICCSPP48568.2020.9182255



- Rao, D. S., Ch, R. B., Kiran, V. S., Rajasekhar, N., Srinivas, K., Akshay, P. S., Mohan, G. S., & Bharadwaj, B. L. (2022). Plant Disease Classification Using Deep Bilinear CNN. *Intelligent Automation & Soft Computing*, 37(1), 161–176. DOI: 10.32604/iasc.2022.017706
- Ristaino, J.B., Anderson, P.K., Bebbler, D.P., Brauman, K.A., Cunniffe, N.J., Fedoroff, N.V., Finegold, C., Garrett, K.A., Gilligan, C.A., Jones, C.M., Martin, M.D., MacDonald, G.K., Neenan, P., Records, A., Schmale, D.G., Tateosian, L. & Wei, Q. (2021). The persistent threat of emerging plant disease pandemics to global food security. *Proceedings of the National Academy of Sciences of the United States of America*, 118(23). DOI: 10.1073/pnas.2022239118
- Sagar, A., & Jacob, D. (2021). *On Using Transfer Learning For Plant Disease Detection*. DOI: 10.1101/2020.05.22.110957
- 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 (CVPR), 2018, pp. 4510–4520. DOI: 10.1109/CVPR.2018.00474
- Shahoveisi, F., Taheri Gorji, H., Shahabi, S.M., Hosseinirad, S.A., Markell, S. & Vasef, F. (2023). Application of image processing and transfer learning for the detection of rust disease. *Scientific Reports*, 13, Article 31942. DOI: 10.1038/s41598-023-31942-9
- Shrivastava, V.K., Pradhan, M.K., Minz, S. & Thakur, M.P. (2019). Rice Plant Disease Classification Using Transfer Learning of Deep Convolution Neural Network. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(3/W6). DOI: 10.5194/isprs-archives-XLII-3-W6-631-2019
- Sibiya, M. & Sumbwanyambe, M. (2019). A computational procedure for the recognition and classification of maize leaf diseases out of healthy leaves using convolutional neural networks. *AgriEngineering*, 1(1), 119-131. DOI: 10.3390/agriengineering1010009
- Simonyan, K. & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv Preprint*. DOI: 10.48550/arXiv.1409.1556
- Vallabhajosyula, S., Sistla, V., & Kolli, V. K. K. (2024). A novel hierarchical framework for plant leaf disease detection using residual vision transformer. *Heliyon*, 10(5), e29912. DOI: 10.1016/j.heliyon.2024.e29912
- Vangala Rama Vyshnavi ve ark. (2019). Efficient of web development using Python and Flask. *International Journal of Recent Research way Aspects*, 6(2), 16–19.
- Walleign, S., Polceanu, M., & Buche, C. (2018). Soybean plant disease identification using convolutional neural networks. In: The Thirty-First International FLAIRS Conference.
- Wang, G., Sun, Y. & Wang, J. (2017). Automatic image-based plant disease severity estimation using deep Learning. *Computational Intelligence and Neuroscience*. DOI: 10.1155/2017/2917536
- Wasswa, Ş., Tufail, A., De Silva Liyanage, C. ve Awg Haji Mohd Apong, R. A. (2024). Using transfer learning-based plant disease classification and detection for sustainable agriculture. *BMC Plant Biology*, 24, Article 136. DOI: 10.1186/s12870-024-04825-y
- Xie, W., Wei, S., Zheng, Z., Jiang, Y. & Yang, D. (2021). Recognition of defective carrots based on deep learning and transfer learning. *Food and Bioprocess Technology*, 14(7), 1-14. DOI: 10.1007/s11947-021-02653-8
- Xu, M., Yoon, S., Jeong, Y. ve Park, D. S. (2022). Transfer learning for versatile plant disease recognition with limited data. *Frontiers in Plant Science*, 13. DOI: 10.3389/fpls.2022.1010981
- Yang, M., He, Y., Zhang, H., Li, D., Bouras, A., Yu, X. & Tang, Y. (2019). The research on detection of crop diseases ranking based on transfer learning. In International Conference on Information Science and Control Engineering (ICISCE), Shanghai. DOI: 10.1109/ICISCE48695.2019.00129
- Yosinski, J., Clune, J., Bengio, Y. & Lipson, H. (2014). How transferable are features in deep neural networks? In *Advances in Neural Information Processing Systems*, ss. 3320-3328. DOI: 10.48550/arXiv.1411.1792
- Zhao, X., Li, K., Li, Y., Ma, J. & Zhang, L. (2022). Identification method of vegetable diseases based on transfer learning and attention mechanism. *Computers and Electronics in Agriculture*, 193, 106703. DOI: 10.1016/j.compag.2022.106703.