



## Konvolüsyonel Sinir Ağı Tabanlı Derin Öğrenme Modeli ile Narenciye Hastalıklarının Sınıflandırılması

Halit ÇETİNER<sup>1\*</sup>, İbrahim ÇETİNER<sup>2</sup>

<sup>1</sup>Teknik Bilimler MYO, Isparta Uygulamalı Bilimler Üniversitesi, Isparta, Türkiye

<sup>2</sup>Teknik Bilimler MYO, Mehmet Akif Ersoy Üniversitesi, Burdur, Türkiye

(ORCID: [0000-0001-7794-2555](https://orcid.org/0000-0001-7794-2555)) (ORCID: [0000-0002-1635-6461](https://orcid.org/0000-0002-1635-6461))



**Anahtar kelimeler:**  
CNN, Narenciye yaprak hastalığı, Sınıflandırma, Transfer öğrenme.

### Öz

Tarımsal üretimde mahsul verimi için bitki hastalıkları hayati öneme sahiptir. Bitkilerde bulunan renk, şekil, doku gibi özelliklerin birbirine benzemesinden dolayı bitkilerdeki hastalıkların erken aşamada tespiti zor ve yorucu olmaktadır. Bitkilerdeki hastalıkların erken aşamada tespit edilerek önlem alınması mahsule gelen zararın engellemesi için gerekli bir adımdır. Bu nedenle, narenciye ihracatını etkileyerek üreticileri maddi olarak büyük zararlara uğratan yaprak hastalıklarını sınıflandırmak için yapılan çalışma kapsamında derin öğrenme tabanlı bir model geliştirilmiştir. Buna ek olarak DenseNet121, MobileNetV2 ve ResNet50 modellerini temel alan üç ayrı model ile de yaprak hastalıkları sınıflandırılmıştır. Bu modellerin oluşturulmasında ince ayarlı transfer öğrenme tekniği kullanılmıştır. Yapılan çalışma kapsamında önerilen 15 katmanlı CNN modeli ile Adamax optimizasyon yöntemi ile %99, RMSProp optimizasyon yöntemi ile de %97 doğruluk oranlarına ulaşılmıştır. En sık karşılaşılan narenciye yaprak hastalıklarından olan Blackspot (narenciye siyah nokta (CBS)), canker (narenciye bakteriyel kanseri (CBC)), greening (huanglongbing (HLB)) ile Health (sağlıklı (Health)) sınıflarında ise sırasıyla %100, %100, %98 ve %100 başarı oranlarına erişilmiştir.

## Classification of Citrus Diseases with Convolutional Neural Network Based Deep Learning Model

**Keywords:** CNN, Citrus leaf disease, Classification, Transfer learning.

### Abstract

Plant diseases are of vital importance for crop yield in agricultural production. It is difficult and tiring to detect diseases in plants at an early stage due to the similarity of features such as colour, shape and texture in plants. Detecting diseases in plants at an early stage and taking precautions is a necessary step to prevent damage to the crop. For this reason, a deep learning-based model has been developed within the scope of the study to classify leaf diseases that affect citrus exports and cause great financial losses to producers. In addition, leaf diseases were classified with three different models based on DenseNet121, MobileNetV2 and ResNet50 architectural models. Fine-tuned transfer learning technique was used in the creation of these models. With the 15-layer CNN model proposed within the scope of the study, 99% accuracy rates were achieved with the Adamax optimization method and 97% with the RMSProp optimization method. In Blackspot (citrus black spot (CBS)), canker (citrus bacterial cancer (CBC)), greening (huanglongbing (HLB)) and Health (Health) classes, which are the most common citrus leaf diseases, 100%, 100%, 98% and 100% success rates have been achieved respectively.

\*Sorumlu yazar: [halitcetiner@isparta.edu.tr](mailto:halitcetiner@isparta.edu.tr)

Geliş Tarihi: 25.11.2021, Kabul Tarihi: 17.01.2022

## 1. Giriş

Makine öğrenme ve yapay zekâ alanında, derin öğrenme oldukça aktif araştırma alanlarından biridir. Derin öğrenme, klasik makine öğrenme yöntemlerinden olan ön işlemler, öznitelik çıkarma, seçme, dönüştürme ve sınıflandırma süreçlerini birlikte yürüten bir makine öğrenme alt kümesidir [1]. Bitki hastalıklarının tespiti ve sınıflandırılması olmak üzere çok farklı alanlarda kapsamlı uygulamaları mevcuttur [2]–[8]. Derin öğrenme modellerinin artan kullanımı ile birlikte özellikle sınıflandırma görevinde dikkat çekici gelişmeler yaşanmaktadır [9]. Bununla sınırla kalmayıp tarımsal uygulamalarda tahmin, görüntü iyileştirme, dönüştürme, yeniden yapılandırma gibi farklı görevlerde kullanılır duruma gelmiştir [10]–[12].

Narenciye hastalığının zamanında ve doğru bir şekilde tanımlanmasını engelleyen ana nedenlerden birisi bitki patolojisi alanındaki uzmanların az olmasıdır. Hastalığın yanlış teşhis edilmesi ve değerlendirilmesi, hastalığın diğer ağaçlara ya da yapraklara bulaş riskini artırmaktadır. Görüntü işleme teknikleri ve derin öğrenme yardımıyla bitki hastalıklarının uzman yardımı almaksızın otomatik tanımlanması, tarım alanında büyük bir dönüşüm sağlamıştır. Bu sayede uzun yıllardır problem olmuş sıkıntı ve zorlukların üstesinden gelecek modeller geliştirilmektedir. Narenciye üretiminde en sık görülen HLB, CBC, CBS adlı hastalıkların tespiti ve sınıflandırılması üzerine yapılan çalışmalar incelenmiştir. Bu çalışmalarda, görüntü işleme adımları olan ön işleme, bölütleme, öznitelik çıkarma ve sınıflandırma gibi adımlardan oluşmaktadır [34].

Literatürde iki farklı yapıda çalışmalar bulunmaktadır. Bu çalışmalar derin öğrenme tabanlı çalışmalar ve derin öğrenme tabanlı olmayan çalışmalar olmak üzere iki gruptan oluşmaktadır. Rauf vd. [35] CBS, CBC, HLB gibi farklı hastalık gruplarındaki görüntülerden oluşan bir veri seti hazırladı. Hazırladığı veri setinde sağlıklı ve hastalıklı olmak üzere toplam 759 görüntü bulunmaktadır. Xing vd. [36], Chen vd. [37] narenciye zararları ve hastalıklarının otomatik tanımlanması için DenseNet adında bir CNN modeli önermiştir. Oluşturdukları modelde görüntüler arasındaki benzerlik oranını azaltmak için veri büyütme algoritması kullanmıştır. Syed-Ab-Rahman vd. [19] bitki hastalığının tespit ve sınıflandırma için

iki aşamalı bir CNN yöntemi önermiştir. Birinci aşamada potansiyel hastalıklı bölgeleri tespit etmektedir. İkinci aşamada ise hastalıklı lezyon alanları belirlenen CBC, CBS, HLB sınıf guruplarını tahmin eden sınıflandırma işlemini yapmaktadır.

Derin öğrenme tabanlı olmayan çalışmalarda ise; Şerif vd. [38] bölütleme yöntemiyle çıkartılan hastalıklı lezyon bölgelerinden renk, doku ve geometrik özelliklere göre öznitelik matrisi elde etti. Elde edilen öznitelikleri PCA, entropi, kovaryans gibi vektörler kullanarak en iyi olanlarını seçti. Seçilen en iyi öznitelikler çok sınıflı destek vektör makine yöntemi ile sınıflandırılmıştır. Senthilkumar vd. ise Hough dönüşümü ile öznitelikleri çıkarttıktan sonra yapay sinir ağları ile narenciye bitkisine ait hastalıkları tanımlamıştır. Wetterich vd. [39] CBC ve HLB tipi hastalıkları belirlemek için floresan görüntüleme spektroskopisi kullandı. Bu teknikten elde edilen öznitelikleri destek vektör makinesi yöntemiyle sınıflandırmıştır.

Son zamanlarda tarım arazilerinde ve bahçe uygulamalarında mahsul sınıflandırması, hastalık tespiti, ürünlerin kalite sınıflandırması için de kullanılmaktadır [13]. Yaşanan aşırı sıcaklık artışı ve yangınlar küresel açlığı artırmaktadır. İklim değişikliği ise son doğa olaylarının ana sebebi olarak görülmektedir. Nüfus artışı, miras sebebiyle değişen arazi kullanım değişiklikleri ana sebepler ile birleştiğinde gıda güvenliği üzerinde derin etkiler bırakacağı öngörülmektedir [14]. Bu gerçekler doğrultusunda düşünüldüğünde tarım mahsullerinde verim düşüşü ve üretim azalması beklenmektedir. Belirtilen tespit doğrultusunda küresel gıda ihtiyacının 2050 yılına doğru yaklaşık olarak %56 oranında artması, açlık riski altındaki nüfusun %91 oranında değişiklik göstermesi tahmin edilmektedir [15]. Özetle, küresel ısınma, su kaynaklarının azalması, yangın, sel gibi sebeplerin yanında bitki hastalıkları tarım üretimini ve verimini derinden etkileyen gıda güvensizliğine sebep olan ana sorunlardan birisidir. Bu sebeplerden dolayı bitki üretim ve veriminde gıda güvenliğini artıracak önlemlerin alınması için yeni, özgün çalışma ve yöntemlere ihtiyaç duyulmaktadır. Tarım alanındaki zararlıların ve hastalıkların belirlenmesi büyük ölçüde uzmanlar tarafından yapılan görsel muayeneler ile tespit edilmektedir. Bununla birlikte yoğun mesai ve uzun çalışma günleri sonucunda aşırı dikkat kayıpları yaşanmaktadır. Yorgunluk ve dikkatsizlik sonucunda uzmanlar hataya açık duruma gelmektedir. Uzmanlara yardımcı, onların bu aşırı iş

yükünü hafifletecek derin öğrenme tabanlı sistemlere ihtiyaç duyulmaktadır.

Bitkilerde narenciye ürünü büyük bir ekonomik öneme sahip bir meyvedir [16]. Ancak narenciye üretimi çeşitli hastalıklar ve zararlılardan geniş ölçüde etkilenmektedir. Belirtilen etkilerin sonucunda önemli verim ve kalite kayıpları yaşanmaktadır. Narenciye en çok ticareti yapılan ve dünyada en çok tüketilen meyve ürünü olmasından dolayı, bu alanda yaşanan verimlilik düşüşü, kalite kaybı ve üretim azalması büyük ekonomik kayıplara sebep olmaktadır. Ekonomik olarak meydana gelen kayıpları engelleyebilmek için narenciye üretiminde en sık görülün hastalıkların engellenmesi gerekmektedir. Bu hastalıklar sırasıyla CBS, CBC, HLB adlı hastalıklardır [17]. Özellikle ejderha hastalığı olarak da tanınan HLB tipi hastalığa yakalanmış narenciye ağaçlarının zamanında ve doğru bir şekilde tespit edilmesi aşırı önem taşımaktadır. Çünkü HLB tipi hastalığa yakalanan narenciye tarlalarında bu hastalığı engelleyebilmek için HLB bulaşmış tüm ağaçlar kesilmektedir [18]. Bu yöntemden başka farklı bir yol ya da yöntem bulunmamaktadır. *Xanthomonas* narenciye çeşitlerinin birçoğunu etkileyen, dünya genelinde narenciye üretiminde büyük engellemelere sebep olan CBC hastalığını oluşturan bakteriyel patojendir [19]. CBC hastalığı havanın yağış, sıcaklık, nem, rüzgar gibi farklı durumlarına göre yayılımı değişmektedir. Nemli ve yağmurlu iklim koşullarında daha hızlı yayılmaktadır [20]. CBC hastalığının belirtileri arasında olgunlaşma dönemi öncesinde erken yaprak ve meyve dökümü, kahverengi lezyon ve ağacın farklı bölgelerinde oluşan kabarcık oluşumu vardır [21]. Şiddet sıralamasına göre son hastalık çeşidi CBS ise *Phyllosticta citricarpa* adlı mantar patojeninden kaynaklanan bir narenciye hastalığıdır [22].

Son yıllarda konvolüsyon sinir ağları (CNN) kullanarak geliştirilen bilgisayar gözü uygulamalarında büyük gelişmeler yaşanmaktadır. Öznitelik çıkarma ve seçme adımlarını CNN yapısını oluşturan katmanlar ile gerçekleştirebilen modeller meydana getirilmektedir. Bu modellerden bazıları DenseNets [23], Microsoft ResNet [24], Google Inception V3 [25], Inception V4 [26] modelleridir. Bu model başlıklar altında temel olarak benzer olmakla birlikte farklı modeller geliştirilmiştir. Bu derin ağlar eğitim sürecinde gradyan bozulması, aşırı öğrenme gibi farklı

sorunlara sahip olabilmektedir. Bu sebepler ile birlikte adım sayısı maksimum değeri aştığında eğitim ve doğruluk oranlarında bozulmalar ve azalmalar meydana gelmektedir. Bunun yanı sıra eğitim sırasında katmana giriş verisi dağılımı değişmesinden kaynaklanan problemler vardır. Bunlar gibi pek çok problemleri çözebilmek adına transfer öğrenme [27], atlama bağlantıları [24], optimizasyon stratejileri [28], Batch Normalization (toplu normalleştirme (BN)) [29] gibi optimizasyon teknikleri geliştirilmiştir.

Görüntü sınıflandırmasındaki ilerlemeler, görüntü işleme araştırma ve uygulama alanlarının her geçen gün genişlemesi, bu alanda şu ana kadar oluşan bilgi birikimini tarım alanına aktarmak için bir fırsat sunmaktadır [2], [11], [13], [30], [31]. Bu fırsatı değerlendirmek için iki farklı yol bulunmaktadır. Yollardan bir tanesinde CNN'e ait convolutional (konvolüsyon), BN, pooling (havuzlama), dropout (unutma), fully connected (tam bağlantı (FC)) gibi ana katmanları veri setine uygun dizilimler oluşturarak bir model oluşturmaktan ibarettir. Bir diğerinde ise kullanılan veri setine göre DenseNets, ResNet, Inception V3 ve InceptionV4 modellerini temel alacak transfer öğrenme tekniği ile farklı modelleri oluşturmaktan geçmektedir. Narenciye hastalıklarının zamanında ve doğru tespiti, bitkide oluşan zararlıların ve hastalığın ilerlemesini engelleyebilmek için önemlidir. Doğru ve zamanında narenciye hastalıklarının en yaygın hastalık tiplerini tespiti ve sınıflandırılabilmesi için her iki yaklaşım önemli özelliklerinden bir CNN modeli geliştirilmiştir. Bu modelden elde edilen sonuçlar narenciye yetiştiricilerinin ve üreticilerinin hastalıkları tanınması, tespiti ve sınıflandırılmasında faydalı bir karar destek aracı olarak hizmet etmesi hedeflenmektedir. Önerilen modelden en yüksek başarı oranı %95.3 olarak elde edilmiştir. Bugüne kadar narenciye hastalıklarının ve zararlılarının kontrol edebilmek, bunun yanı sıra verim, kalite kayıplarını önleyebilmek için yapılan çabalar incelenmiştir. Bunlar incelendiğinde hastalığın zamanında ve doğru bir şekilde tespitinin hastalığın yayılmasını engelleyici en önemli yol olarak kabul edilmektedir. Bu işlem tarım alanında narenciye üretiminin sürdürülebilirliğini sağlayabilmek için kritik öneme sahiptir. Son yıllarda narenciye ürünü dışındaki farklı bitkilere ait hastalıkların tanınmasına ve sınıflandırılmasına yönelik kapsamlı görüntü tanıma uygulamaları geliştirilmiştir [22], [32], [33]. CNN tabanlı derin öğrenme yaklaşımlarında klasik makine öğrenme ve yapay zekâ yaklaşımlarındaki gibi öznitelik çıkarma adımına gerek yoktur. CNN modellerinde bulunan

konvolüsyon katmanları ile öznelik çıkarma, havuzlama katmanları ile de öznelik indirgeme gerçekleştirilmektedir [19]. Bu işlemleri, CNN tabanlı yöntemlerin kendi içerisinde otomatik olarak çözme yeteneği sayesinde daha yüksek doğruluk elde edilmektedir.

Bu makalenin ana katkısı maddeler şeklinde verilmiştir.


- Narenciye yapraklarındaki hastalıkları, hastalık belirtilerine göre sınıflandırılması ve hastalıklı bölgeleri tespit edebilen derin öğrenme modeli geliştirilmesidir.
- Önerilen modelin bir diğer katkısı narenciye hastalıklarının zamanında ve doğru tanı koyulabilmesi için uzmanlara yardımcı erken uyarı sistemi görevi görmesidir.
- Herhangi bir uzman yardımı almadan narenciye bitki hastalıklarını otomatik tespit etmek ve gerçek tarla koşullarında gerçek zamanlı çalışan donanımsal sistemlere destek olması açısından faydalı bir model geliştirilmiştir.
- Geliştirilen model ile zamanında ve doğru tanı koyarak yanlış ve gereksiz

tarım ilacı kullanmanın önüne geçmeye çalışılmaktadır.

Makalenin geri kalan bölümleri aşağıdaki şekilde kurgulanmıştır. Malzeme ve yöntemler adlı bölümde ise narenciye veri seti ve yöntemlerden bahsedilmiştir. Öne sürülen metot bölümünde ana katkı olarak belirtilen adımları gerçekleştiren CNN modeli hakkında detaylı bilgi verilmiştir. Sonrasında yine aynı bölümde geliştirilen modelden elde edilen deneysel sonuçlar verilmiştir. Son olarak sonuç kısmında makale sonuçlandırılmıştır.

## 2. Materyal ve Metot

Kaggle, farklı veri setlerini içinde barındıran, veri setlerini işlemek için araç ve kaynaklara sahip dünya çapındaki en büyük veri seti topluluğudur. Bu çalışma kapsamında önerilen modellerin performansları narenciye bitkilerine ait yaprak görüntülerini içeren halka açık bir veri seti [40] üzerinde test edilmiştir. Test edilen veri setinde [40] HLB, CBS, CBC adlı narenciye yaprak hastalıklarına ait görüntüler bulunmaktadır. Veri kümesi içerisinde eğitim ve test olmak üzere iki farklı grup vardır. Her iki grubun içerisinde HLB, CBS, CBC ve sağlıklı olmak üzere dört sınıfa ait sayıları birbirinden farklı görüntüler bulunmaktadır.



Şekil 1. Veri setinde bulunan narenciye görüntülerinin sınıf dağılımları

Şekil 1'de bu makale kapsamında kullanılan veri setine ait sınıf gruplarının isimleri ve sayısal dağılımları gösterilmiştir. Bu sınıf dağılımlarındaki sayılar, ilgili sınıfa ait toplam eğitim ve test sayılarını göstermektedir. Tablo 1'de ise çalışmada öne sürülen metotların eğitiminde kullanılan verilerin sayısal dağılımları gösterilmiştir. Eğitim ve test verilerini ayırmak için K-Fold 5 değeri kullanılmıştır. Aynı zamanda eğitilen modelleri kullanarak test işleminde kullanılan test görüntülerinin sınıf dağılımları Tablo 1'de gösterilmiştir. Veri setindeki görüntülerin dengeli dağılımını sağlamak ve veri sayısını artırmak için döndürme ve yakınlaştırma yöntemleri ile veri büyütme işlemi

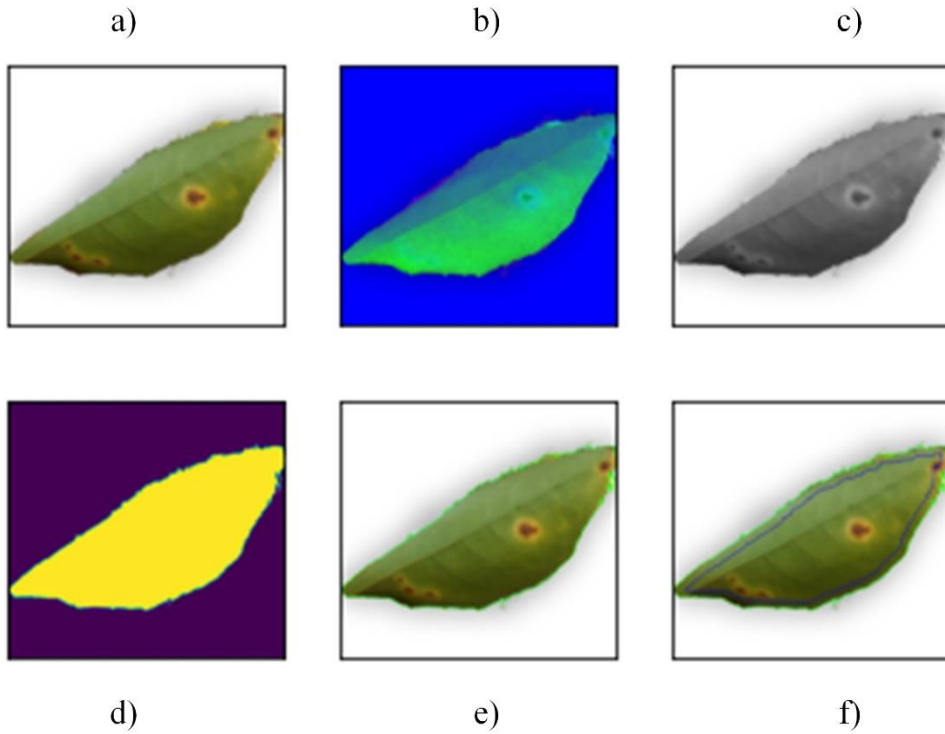
gerçekleştirilmiştir. Bu yaklaşımla veri sayısı artırılarak model eğitimin elde edilmesinde kullanılan görüntüler test işlemlerinde kullanılmamıştır. Verileri eğitim modelleme işlemine hazırlamak için veri seti görüntüleri üzerinde ön işleme uygulanmıştır. Şekil 2'de gösterildiği gibi eğitim sırasında tüm görüntüler bu ön işleme adımlarından geçmektedir. Ön işleme sonrasında görüntü 64x64 boyutuna getirilmiştir. Bu işlemler sonrasında görüntü yoğunluğu standart hale getirilmiştir.

**Tablo 1.** Kullanılan veri seti sınıf dağılımları

Sınıf Tipi	Eğitim Sayıları	Test Sayıları
Healthy	46	12
HLB	163	41
CBC	130	33
CBS	138	35
Toplam	477	121

HSV renk uzayı, görüntülerdeki ışık patlamaları ve parlaklık farklılıklarının daha görünür olması sağlanmaktadır. Bu sebepten dolayı RGB renk uzayından HSV renk uzayına görüntüler ilk adımda dönüştürülmüştür. Daha sonrasında görüntüler, 3 kanallı renk uzayından

gri tonlamalı görüntüye dönüştürülerek eşiklemeye hazır hale getirilmiştir. Denklem 1-4 arası tanımlanan Otsu yöntemi ile görüntünün ikili formatlı hali elde edilmiştir. Bu sayede sınırlayıcı alanların bulunması sağlanmıştır. Şekil 2e adımında ise elde edilen ilgili alan (ROI) bölgesinin etrafı belirlenmiştir. Şekil 2f adımında ise görüntü dışındaki alanın renk piksel değerleri beyaza döndürülerek konvolüsyon işlemlerdeki negatif etkisinin önüne geçilmiştir. Bunlara ek olarak Şekil 2f adımında Şekil 2e adımında elde edilen sınır koordinatlarına denk gelen bölge, orijinal RGB görüntüsünden alınmıştır. Bu sayede konvolüsyon işlemlerinde görüntünün orijinal renk uzayı olan RGB renk uzayında çalışılmasına devam edilmiştir.



**Şekil 2.** Ön işleme adımları: a) Orijinal, b) HSV, c) Gri format, d) İkili + Otsu, e) Etrafı çizilmiş ROI, f) Temizlenmiş ROI

Denklem 1’de kullanılan  $q_1$  ifadesinin açılımı Denklem 2’de verilmiştir. Denklem 1’de tanımlanan  $\sigma_1^2(t)$  ifadesi ise Denklem 4’te verilmiştir.  $\mu_1(t)$  ise Denklem 2’de ifade edilen ortalama hesaplama değerinin ifade etmektedir. Otsu yönteminde sınıf içi varyans değeri en aza indirilmeye çalışılmaktadır. Varyans değerini en aza indirebilecek olan  $t$  değeri araştırılmaktadır.

$$\sigma_w^2(t) = q_1(t)\sigma_1^2(t) + q_2(t)\sigma_2^2(t) \quad (1)$$

$$q_1(t) = \sum_{i=1}^t P(i) \quad \& \quad q_2(t) = \sum_{i=t+1}^L P(i) \quad (2)$$

$$\mu_1(t) = \sum_{i=1}^t \frac{iP(i)}{q_1(t)} \quad \& \quad \mu_2(t) = \sum_{i=t+1}^L \frac{iP(i)}{q_2(t)} \quad (3)$$

$$\sigma_1^2(t) = \sum_{i=1}^t [i - \mu_1(t)]^2 \frac{P(i)}{q_1(t)} \& \sigma_2^2(t) = \sum_{i=t+1}^L [i - \mu_1(t)]^2 \frac{P(i)}{q_2(t)} \quad (4)$$

Belirtilen ön adımlar, sınıf gruplarına döngü yardımıyla uygulandıktan sonra bir etiketle ilişkilendirilmiştir. Etiketler CBS, CBC, HLB ve Healthy sınıflarından herhangi biri olabilmektedir. Bu etiketler, sınıf sırasına göre 0'da 3'e kadar olan rakamlarla tanımlanmıştır.

Veri hazırlama sürecinde ön işlemler sonrasında sınıflar arası veri dengesizlikleri giderebilmek için döndürme, yakınlştırma gibi çok temel veri büyüme işlemleri gerçekleştirildi. Veri büyüme görüntü sayısı az olan sınıfları aşırı örnekleyerek sınıf başına dengesiz dağılım ile başa çıkmak için yapılmıştır. Elde edilen tüm deney sonuçlarında veri büyüme uygulanmıştır.

## 2.1. DenseNet121

DenseNet, günümüzde sıklıkla kullanılan derin öğrenme modellerinden birisidir [23]. DenseNet modelinin DenseNet121, DenseNet169, DenseNet201 gibi çeşitleri bulunmaktadır. Uygulama hafif donanıma sahip cihazlarda test edilecek olması nedeniyle diğer DenseNet modellerine göre boyutu ve derinliği az olan DenseNet121 modeli tercih edilmiştir. Aynı zamanda bu model geleneksel CNN modellerinden daha az parametre sayısını sahiptir [41]. DenseNet dört adet dense blok ve üç adet transition katmanı içermektedir. Dense blokları 3x3 ve 1x1 konvolüsyon setlerine sahiptir. Buradaki 4 yoğun blok içerisindeki 3x3 ve 1x1 konvolüsyonlar 6, 12, 24 ve 16 defa tekrarlamaktadır. İki dense katmanı arasında bir transition katmanı bulunmaktadır. Bir dense blok içerisinde her konvolüsyon katmanı ileri beslemeli olarak bir diğer konvolüsyon katmanına bağlıdır. Transition katmanı toplu normalleştirme, 1x1 konvolüsyon ve stride değeri 2 olan 2x2 ortalama havuzlama yapısından oluşmaktadır. Denklem anlamında ifade etmek gerekirse;

$$x_n = H_n(x_{n-1}) \quad (5)$$

DenseNet modellerinde giriş katmanları, çıkış katmanları ile birleştirilmektedir, ancak her iki katmanın toplaması yapılmamaktadır. Bu sebepten dolayı

Denklem 5 yeniden oluşturulduğunda Denklem 6 oluşmaktadır.

$$x_n = H_n([x_0, \dots, x_{n-1}]) \quad (6)$$

Denklem 6'da n. katmandaki öznitelik haritası  $x_n$  ile gösterilirken, diğer öznitelik haritaları ise katman sırasına göre  $x_0, \dots, x_{n-1}$  şeklinde gösterilmiştir. Denklem 6'da tanımlanan  $H_n$  BN, ReLU ve 3x3 boyutunda filtrelerden oluşan konvolüsyon katmanlarının birleşmesinden meydana gelmektedir.

## 2.2. MobileNetV2

DenseNet modellerinden hafif olması, taşınabilir mobil cihazlar üzerinde kullanılabilmesi sebebiyle çok fazla tercih edilen modellerden birisidir [42]. Bunlara ek olarak mobil telefonlardaki bilgisayar görü uygulamaları için tasarlanmış bir derin öğrenme modelidir. Diğer modellere göre hafif, daha az kompleks ve hızlı olması tercih edilmesinin sebeplerindedir.

Birden fazla kanaldan oluşan giriş görüntüsüne ait her bir kanala belirli derinlik seviyesinde iki boyutlu bir filtre uygulanmaktadır. MobileNetV2 modelinde Depthwise Seperable Convolution (derinlemesine ayrılabilir konvolüsyon (DWC)) yöntemi tercih edilmektedir. DWC, depthwise convolution (derinlemesine konvolüsyon (DC)) yöntemine ek olarak 1x1 boyutunda bir filtre işlemi daha gerçekleştirilmektedir. MobileNetV2 modeli, ilk versiyonundan hafif olmasının yanında çıkış kanallarının daraltılarak ağırlık sayısının da azaltıldığı bilinmektedir. Bunlara ek olarak veri matrislerinin her noktasına uygulanan bir konvolüsyon operatörü vasıtasıyla noktasal konvolüsyon yöntemi gerçekleştirilmektedir. Sonuç olarak ilk versiyona göre yapılan yenilikler ile performansı artırılmıştır. Yapılan bu yeniliklere bottleneck denilmektedir. Şekil 3'te gösterilen şekilde MobileNetV2 modeli  $t$ ,  $c$ ,  $n$  ve  $s$  değerleri ile tanımlanmaktadır. Giriş boyutlarına uygulanan genişleme değerleri, çıkış kanal sayısı ve atlama değerleri sırasıyla  $t$ ,  $c$ ,  $n$  ve  $s$  olarak gösterilmiştir.  $1e-3$  öğrenme oranı ile temel bottleneck yapısına sahip MobileNetV2 modeline farklı katmanlar eklenerek bitki hastalıkları tanımlanabilir.

### 2.3. ResNet50

Günümüzde bitki hastalıklarının tespit ve sınıflandırılmasında kullanılan derin öğrenme modellerinden birisi de ResNet50 modelidir. ResNet modelinin blok ve katman yapısına göre 18/50/101 ve 152 olmak üzere farklı yapıları bulunmaktadır [44]. Model içerisinde bulunan en önemli yapılardan birisi Residual Building Block (RBB) yapısıdır. RBB içerisinde ise atlayan kısa yol bağlantıları bulunmaktadır. Bu bağlantılar sayesinde yerel optimum noktasına takılma sorunu çözülmüştür. RBB'ler Conv, BN, ReLU katmanlarına ek olarak bir kısa yoldan oluşmaktadır. RBB yapılarının ise RBB-1 ve RBB-2 olmak üzere iki farklı yapısı bulunmaktadır. RBB-1 yapısında kısa yollar  $x$ , doğrusal olmayan fonksiyon  $F$  ile gösterilmiştir. Belirtilen parametreler ile RBB-1'in çıkışını gösteren  $y$  ise Denklem 7'de gösterilmiştir.

$$y = F(x) + x \quad (7)$$

RBB-2 yapısında ise RBB-1 yapısı üzerine bir adet konvolüsyon ve toplu normalleştirme katmanı daha eklenmiştir. Birlikte eklenen bu katmanlar  $H$  ile ifade edilirse Denklem 8 oluşmaktadır.

$$y = F(x) + H(x) \quad (8)$$

Vallabhajosyula et al. [45] çalışmasında RBB-1 ve RBB-2 yapılarına ait formülleri aşağıdaki şekilde ifade etmiştir.

$$y_n = H(x_n) + F(x_n, W_n) \quad (9)$$

$$x_{n+1} = F(y_n) \quad (10)$$

Denklem 9 ve 10'da  $x_n$  girdiyi,  $x_{n+1}$  ise nth birimin çıktısını göstermektedir.  $F$  ise nth birimin residual fonksiyonunu temsil etmektedir.

$$H(x_n) = x_n \quad (11)$$

Geri yayılım sayesinde gradyan sorunu olmaması ve bazı ağırlık katmanlarından sonra atlama bağlantıları ile girdi değerleri çıktı değerlerine eklenebilmesi ResNet50 modelinin kullanım oranını artırmıştır.  $1e-3$  öğrenme oranı ile temel ResNet50 modeline farklı katmanlar eklenerek bitki hastalıkları tanımlanabilir.

Giriş	Operatör	$t$	$c$	$n$	$s$
224 x 224 x 3	Konvolüsyon 2D	-	32	1	2
112 x 112 x 32	bottleneck	1	16	1	1
112 x 112 x 16	bottleneck	6	24	2	2
56 x 56 x 24	bottleneck	6	32	3	2
28 x 28 x 32	bottleneck	6	64	4	2
14 x 14 x 64	bottleneck	6	96	3	1
14 x 14 x 96	bottleneck	6	160	3	2
7 x 7 x 160	bottleneck	6	320	1	1
7 x 7 x 320	Konvolüsyon 1 2D 1 x 1	-	1280	1	1
7 x 7 x 1280	Havuzlama (Ortalama) 7 x 7	-	-	1	-
1 x 1 x 1280	Konvolüsyon 2D 1 x 1	-	k	-	-


Şekil 3. MobileNetV2 modeli [43]

### 3. Bulgular ve Tartışma

Literatürde yaygın olarak kullanılan Adamax ve RMSProp optimizasyon algoritmaları, modellerin performanslarını değerlendirmede kullanılmıştır. Sonuçlar ve tartışma bölümünde ince ayarlı transfer öğrenme tekniğini kullanan sırasıyla ResNet50, MobileNetV2 ve DenseNet121 modellerinin sonuçları sunulmuştur. Buna ek olarak bu bölümün son başlığında ise önerilen

CNN modelinin eğitim, test sonuçları ve karışıklık (confusion) matrisi verilmiştir.


ResNet50 modeli, hafif olmasından dolayı tercih edilmiştir. ResNet50 modeli kullanılarak narenciye yaprak hastalıklarının sınıflandırılmasından elde edilen eğitim doğruluk ve kayıp sonuçları Şekil 4'te verilmiştir.



Şekil 4. ResNet50 eğitim doğruluk ve kayıp grafiği

Şekil 5'te ise eğitimde kullanılmayan test görüntülerinin modele girdi olarak verilmesi ile elde edilen test sonuçları verilmiştir. Sonuçlar dikkatli olarak incelendiğinde her iki optimizasyon

yönteminin de birbirine yakın sonuçlar verdiği gözlenmiştir.




Şekil 5. ResNet50 test doğruluk ve kayıp grafiği

MobileNetV2 modeli, ResNet50 modelinden de hafif olan bir modeldir. Hafif olması ve taşınabilir cihazlarda kullanılmasından dolayı bu çalışma kapsamında kullanılmıştır. MobileNetV2 modeli kullanılarak narenciye

yaprak hastalıklarının sınıflandırılmasından elde edilen eğitim doğruluk ve kayıp sonuçları Şekil 6'da verilmiştir. Şekil 6'da görüldüğü üzere Adamax eğitim doğruluk oranı RMSProp eğitim doğruluk oranından daha büyük ve kararlıdır.






Şekil 6. MobileNetV2 eğitim doğruluk ve kayıp grafiği

Şekil 7'de ise eğitimde kullanılmayan test görüntülerinin modele girdi olarak verilmesi ile elde edilen test sonuçları verilmiştir. Sonuçlar dikkatli olarak incelendiğinde eğitim sonuçları ne


kadar farklı olsa da test işleminde her iki optimizasyon yönteminin de birbirine yakın sonuçlar verdiği gözlenmiştir.



Şekil 7. MobileNetV2 test doğruluk ve kayıp grafiği

DenseNet121, DenseNet model ailesi içerisindeki başarılı ve en hafif ağırlıklı modeldir. Bu modeli kullanarak narenciye yaprak hastalıkları sınıflandırılmaya çalışılmıştır. Bu modelden elde edilen eğitim doğruluk sonuçları


Şekil 8'de verilmiştir. Adamax genel olarak eğitimde RMSProp optimizasyon yönteminden daha iyi bir sonuç verdiği görülmektedir.



Şekil 8. DenseNet121 eğitim doğruluk ve kayıp grafiği

Şekil 9'da ise diğer modellerde olduğu gibi her iki optimizasyon yöntemi birbirine yakın

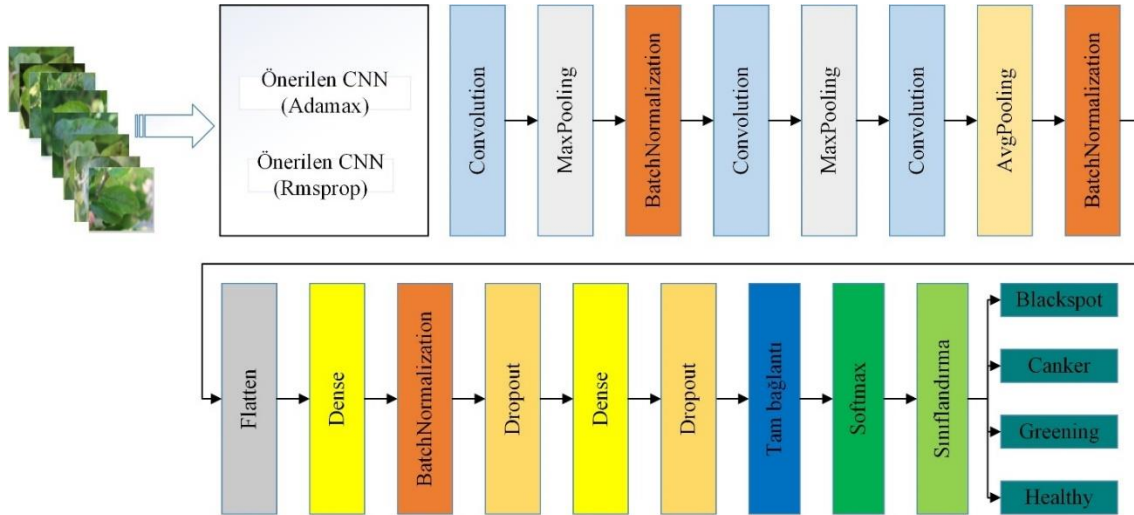
sonuç vermektedir. Test doğruluk oranları arttıkça kayıp da bir o kadar azalmaktadır.



Şekil 9. MobileNetV2 test doğruluk ve kayıp grafiği

Önerilen CNN model katmanları Şekil 10'da sunulmuştur. Önerilen modelin oluşturulmasında 3 adet konvolüsyon katmanı, 2 adet maksimum havuzlama katmanı, 1 adet ortalama havuzlama katmanı, 3 adet toplu normalleştirme, 2 adet Dense katmanı, düzleştirme amacıyla 1 adet Flatten katmanı, ezberlemeyi engellemek için 2 adet unutmaya katmanı, 1 adet softmax aktivasyon fonksiyonlu tam bağlantı katmanı ve sınıflandırıcıdan oluşmaktadır. Toplam 16 katmandan oluşan bir derin öğrenme modeli oluşturulmuştur. Kullanılan her bir konvolüsyon katmanı filtre sayısı 64 tane dir. Bu katmanlardaki filtreler ise 5x5 boyutuna sahiptir. Havuzlama katmanlarında pencere boyutları 2x2 olacak şekilde ayarlanmıştır. Unutmaya katmanlarının her


birisi 0.4 oranında unutmaya gerçekleştirilecek şekilde tanımlanmıştır. İstenilen her özelliği ayrı ayrı normalleştirebilmek için toplu normalleştirmede eksen değeri -1 olarak ayarlanmıştır. Belirtilen 3 adet konvolüsyon katmanının tamamında ReLU aktivasyon fonksiyonu kullanılmıştır. Konvolüsyon katmanları narenciye yapraklarına ait ayırt edici özelliklerin elde edilmesi adına önem taşımaktadır. Yukarıda belirtilen sıralamada önerilen modele ait katmanların görüntüsü Şekil 10'da ayrıntılı olarak gösterilmektedir. Katman türleri aynı olan katmanlar aynı renkte gösterilmiştir.



Şekil 10. Önerilen CNN modeli

Şekil 11’de taslağı gösterilen CNN modeli Adamax ve RMSProp optimizasyon yöntemlerinde genel olarak eğitim sonuçlarında birbirine yakın sonuçlar vermiştir. Ancak genel olarak tüm modellerde Adamax optimizasyon yönteminin


RMSProp optimizasyon yönteminden daha kararlı olduğu görülmektedir.




Şekil 11. RMSProp ve Adamax ile a) Önerilen CNN eğitim doğruluk grafikleri, b) Önerilen CNN kayıp grafikleri

Şekil 12’de ise önerilen CNN modeli, Adamax ve RMSProp optimizasyon yöntemlerinde test edilmiştir. Literatürde yaygın olarak kullanılan precision (kesinlik), recall (geri çağırma), F1 score (f1 puanı) ve accuracy (doğruluk) performans sonuçları incelendiğinde Adamax sonuçları her ne

kadar kararlı olup dalgalanma yapmasa da RMSProp ile yakın sonuçlar vermektedir. Her ikisinin verdiği sonuçlar daha doğru olarak ölçebilmek için Şekil 13’de karışıklık matrisi sunulmuştur.



Şekil 12. a) Önerilen CNN test doğruluk grafiği, b) Önerilen CNN kayıp grafiği



Şekil 13. Önerilen CNN yönteminin a) RMSProp, b) Adamax optimizasyon yöntemleri karışıklık matrisi

Tablo 2’de ise önerilen CNN modelinin farklı optimizasyon yöntemlerindeki performans değerleri verilmiştir. Elde edilen sonuçlardan Adamax optimizasyon yönteminin daha başarılı olduğu belirtilebilir. Burada kullanılan performans ölçütlerinin literatürde karşılığı olan formüllerden olmasına dikkat edilmiştir. Belirtilen mantıkla yapılan performans ölçümleri sonucunda doğruluk değerlerinin literatürdeki uluslararası çalışmalara eş değer seviyelerde sonuçlar verdiği gözlenmektedir. Temel anlamda optimizasyon yöntemlerinin etkisi çok fazla olmamakla beraber önerilen yöntemde ayırt edici özneliliklerine erişim sağlanabildiği ifade edilebilir. Belirtilen sonuçlar ile sınıflar arasındaki ayırmanın net bir şekilde sağlandığı söylenebilmektedir.

Tablo 2’de Şekil 13’te gösterilen sonuçların Tablo 2’de daha anlaşılır olarak

gösterimini sağlamak için 100 değerine bölerek elde edilen sonuçları gösterilmiştir. Şekil 13’te Adamax optimizasyon yönteminde 71 görüntüden 1 tanesini bilemediği görülmektedir. Bu sebepten dolayı sonuç %98.59 olmuştur. Tablo 2’de ise bu sonuç 0.98 olarak yazılmıştır. RMSprop optimizasyon yönteminde ise %93.2 başarı oranı Şekil 13’te 74 görüntüden 2 tanesi bilinmemesinden dolayı elde edilmiştir. Tablo 2’de bu sonuç 0.93 olarak kodlanmıştır.

Tablo 3’te literatürde var olan çalışmalar ile önerilen modelin sonuçları karşılaştırıldı. Narenciye yaprak hastalıklarının etkin ve doğru bir şekilde tespit edilmesinde gerçek zamanlı sistemlere ihtiyaç vardır. Raspberry pi gibi donanımsal cihazlarda çalışabilecek hafif bir model önerilmiştir. Karşılaştırma sonuçlarında da görüldüğü üzere model, literatürdeki çalışmalar

kadar yetkindir. Tablo 3'te ki SAM Spectral Angle Mapper algoritmasını, YSA yapay sinir ağlarını, BPNN iki aşamalı geri yayılım sinir ağını, MINNM ise çok girişli sinir ağı modelini temsil etmektedir.

Belirtilen modellerden elde edilen çalışma sonuçları ile gerçekleştirilen çalışmanın sonuçları karşılaştırılmıştır.

**Tablo 2.** Önerilen CNN performans sonuçları

Optimizasyon Yöntemi	Sınıf	Kesinlik	Geri çağırma	F1-puan	Doğruluk
Adamax	Blackspot	1.00	1.00	1.00	1.00
Adamax	Canker	1.00	0.98	0.99	1.00
Adamax	Greening	0.99	1.00	0.99	0.98
Adamax	Healthy	1.00	1.00	1.00	1.00
					0.99
RMSProp	Blackspot	1.00	1.00	1.00	1.00
RMSProp	Canker	0.98	0.96	0.97	0.97
RMSProp	Greening	0.92	0.99	0.95	0.93
RMSProp	Healthy	1.00	0.76	0.87	1.00
					0.97

**Tablo 3.** Önerilen CNN modelinin farklı çalışmalar ile karşılaştırılması

Sınıflar	Kesinlik (%)	Geri Çağırma (%)	F1 puanı (%)	Doğruluk (%)	Model
CBS	-	-	-	92.0	[46] YSA
	-	-	-	88.6	[47] SAM
	93.8	87.0	90.0	86.1	[19] CNN
	100.0	98.0	100.0	100.0	Önerilen CNN
CBC	-	-	-	89.5	[48] AdaBoost
	-	-	-	93.3	[36] CNN
	99.0	95.8	97.9	97.2	[19] CNN
	100.0	98.0	99.0	100.0	Önerilen CNN
HLB	-	-	-	92.0	[49] BPNN
	-	-	-	93.3	[50] MINNM
	91.0	94.6	93.0	94.64	[19] CNN
	99.0	100.0	99.0	99.0	Önerilen CNN

#### 4. Sonuç

Narenciye yaprak hastalıkları, narenciyenin büyümesini ve kaliteli ürün vermesini engellemektedir. Ürün verimi, kalitesi ve büyümesinin azalmasına sebep olan narenciye yapraklarını erken aşamada tespit ederek sınıflandıran çalışma yapmak kritik öneme sahip bir konudur. Bu kapsamda gerçekleştirilen çalışma ile önerilen CNN tabanlı yöntem ince ayarlanmış transfer öğrenme teknikleri ile üretilen DenseNet121, MobileNetV2 ve ResNet50 modellerinden çok daha iyi bir sonuç vermiştir. CNN, DenseNet121, MobileNetV2 ve ResNet50 modellerinden elde edilen sonuçlar literatürde en yaygın olarak kullanılan performans ölçüm kriterlerinden olan kesinlik, geri çağırma, F1 puanı ve doğruluk değerlerine göre karşılaştırılmıştır. Son olarak elde edilen performans ölçüm sonuçları, literatürdeki çalışmalar ile karşılaştırılmıştır. Bu

karşılaştırmadan elde edilen sonuçlar Tablo 4'te verilmiştir. Bu tabloya da bakıldığında önerilen modelin narenciye yaprak hastalıklarını sınıflandırmak için yardımcı bir araç olarak kullanılabilmesi kanısına varılmaktadır.

#### Yazarların Katkısı

Makalenin tüm adımları sorumlu yazar tarafından tamamlanmıştır.

#### Çıkar Çatışması Beyanı

Yazarın herhangi bir çıkar çatışması bulunmamaktadır.

#### Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

#### Kaynaklar

- [1] E. C. Too, L. Yujian, S. Njuki, and L. Yingchun, 2019. A comparative study of fine-tuning deep learning models for plant disease identification, *Comput. Electron. Agric.*, vol. 161, pp. 272–279, doi: <https://doi.org/10.1016/j.compag.2018.03.032>.
- [2] S. Zhang, W. Huang, and C. Zhang, 2019. Three-channel convolutional neural networks for vegetable leaf disease recognition, *Cogn. Syst. Res.*, vol. 53, pp. 31–41, doi: <https://doi.org/10.1016/j.cogsys.2018.04.006>.
- [3] G. Shrivastava, 2021. Review on Emerging Trends in Detection of Plant Diseases using Image Processing with Machine Learning, *Int. J. Comput. Appl.*, vol. 174, doi: 10.5120/ijca2021920990.
- [4] A. Gargade and S. A. Khandekar, 2019. A Review: Custard Apple Leaf Parameter Analysis and Leaf Disease Detection using Digital Image Processing, in 2019 3rd International Conference on Computing Methodologies and Communication (ICCMC), pp. 267–271, doi: 10.1109/ICCMC.2019.8819867.
- [5] M. Bin Tahir et al., 2021. Recognition of Apple Leaf Diseases using Deep Learning and Variances-Controlled Features Reduction, *Microprocess. Microsyst.*, p. 104027, doi: <https://doi.org/10.1016/j.micpro.2021.104027>.
- [6] P. Bansal, R. Kumar, and S. Kumar, 2021. Disease Detection in Apple Leaves Using Deep Convolutional Neural Network, *Agriculture*, vol. 11, no. 7, doi: 10.3390/agriculture11070617.
- [7] D. Tiwari, M. Ashish, N. Gangwar, A. Sharma, S. Patel, and S. Bhardwaj, 2020. Potato Leaf Diseases Detection Using Deep Learning.
- [8] R. Sujatha, J. M. Chatterjee, N. Z. Jhanjhi, and S. N. Brohi, 2021. Performance of deep learning vs machine learning in plant leaf disease detection, *Microprocess. Microsyst.*, vol. 80, p. 103615, doi: <https://doi.org/10.1016/j.micpro.2020.103615>.
- [9] O. Russakovsky et al., 2015. ImageNet Large Scale Visual Recognition Challenge, *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, doi: 10.1007/s11263-015-0816-y.
- [10] W. Xue, X. Hu, Z. Wei, X. Mei, X. Chen, and Y. Xu, 2019. A fast and easy method for predicting agricultural waste compost maturity by image-based deep learning, *Bioresour. Technol.*, vol. 290, p. 121761, doi: <https://doi.org/10.1016/j.biortech.2019.121761>.
- [11] Z. Zhang, H. Liu, Z. Meng, and J. Chen, 2019. Deep learning-based automatic recognition network of agricultural machinery images, *Comput. Electron. Agric.*, vol. 166, p. 104978, doi: <https://doi.org/10.1016/j.compag.2019.104978>.

- [12] N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, 2017. Deep learning classification of land cover and crop types using remote sensing data, *IEEE Geosci. Remote Sens. Lett.*, vol. 14, no. 5, pp. 778–782.
- [13] A. Z. da Costa, H. E. H. Figueroa, and J. A. Fracarolli, 2020. Computer vision based detection of external defects on tomatoes using deep learning, *Biosyst. Eng.*, vol. 190, pp. 131–144, doi: <https://doi.org/10.1016/j.biosystemseng.2019.12.003>.
- [14] A. Molotoks, P. Smith, and T. P. Dawson, 2021. Impacts of land use, population, and climate change on global food security, *Food Energy Secur.*, vol. 10, no. 1, p. e261, doi: <https://doi.org/10.1002/fes3.261>.
- [15] M. van Dijk, T. Morley, M. L. Rau, and Y. Saghai, 2021. A meta-analysis of projected global food demand and population at risk of hunger for the period 2010–2050, *Nat. Food*, vol. 2, no. 7, pp. 494–501, doi: 10.1038/s43016-021-00322-9.
- [16] M. Dutt, C. El Mohtar, and N. Wang, 2020. Biotechnological Approaches for the Resistance to Citrus Diseases, pp. 245–257.
- [17] N. T. Tran et al., 2017. Sexual Reproduction in the Citrus Black Spot Pathogen, *Phyllosticta citricarpa*, *Phytopathology®*, vol. 107, no. 6, pp. 732–739, doi: 10.1094/PHYTO-11-16-0419-R.
- [18] E. National Academies of Sciences and Medicine, 2018. A Review of the Citrus Greening Research and Development Efforts Supported by the Citrus Research and Development Foundation. Washington, D.C.: National Academies Press.
- [19] S. F. Syed-Ab-Rahman, M. H. Hesamian, and M. Prasad, 2021. Citrus disease detection and classification using end-to-end anchor-based deep learning model, *Appl. Intell.*, doi: 10.1007/s10489-021-02452-w.
- [20] P. M. M. Martins, M. de Oliveira Andrade, C. E. Benedetti, and A. A. de Souza, 2020. *Xanthomonas citri* subsp. *citri*: host interaction and control strategies, *Trop. Plant Pathol.*, vol. 45, no. 3, pp. 213–236, doi: 10.1007/s40858-020-00376-3.
- [21] S. A. de Carvalho et al., 2014. Comparison of Resistance to Asiatic Citrus Canker Among Different Genotypes of Citrus in a Long-Term Canker-Resistance Field Screening Experiment in Brazil, *Plant Dis.*, vol. 99, no. 2, pp. 207–218, doi: 10.1094/PDIS-04-14-0384-RE.
- [22] J. Martínez-Minaya, D. Conesa, A. López-Quílez, and A. Vicent, Climatic distribution of citrus black spot caused by *Phyllosticta citricarpa*. A historical analysis of disease spread in South Africa, *Eur. J. Plant Pathol.*, vol. 143, no. 1, pp. 69–83, doi: 10.1007/s10658-015-0666-z.
- [23] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, 2017. Densely connected convolutional networks, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4700–4708.
- [24] K. He, X. Zhang, S. Ren, and J. Sun, 2016. Identity mappings in deep residual networks, in *European conference on computer vision*, pp. 630–645.
- [25] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. B. Wojna, 2016. Rethinking the Inception Architecture for Computer Vision.
- [26] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, 2017. Inception-v4, inception-resnet and the impact of residual connections on learning.
- [27] M. Khanramaki, E. Askari Asli-Ardeh, and E. Kozegar, 2021. Citrus pests classification using an ensemble of deep learning models, *Comput. Electron. Agric.*, vol. 186, p. 106192, doi: <https://doi.org/10.1016/j.compag.2021.106192>.
- [28] S. Sun, Z. Cao, H. Zhu, and J. Zhao, 2019. A survey of optimization methods from a machine learning perspective, *IEEE Trans. Cybern.*, vol. 50, no. 8, pp. 3668–3681.
- [29] S. Ioffe and C. Szegedy, 2015. Batch normalization: Accelerating deep network training by reducing internal covariate shift,” in *International conference on machine learning*, pp. 448–456.
- [30] B. Liu, Y. Zhang, D. He, and Y. Li, 2018. Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks, *Symmetry (Basel)*, vol. 10, no. 1, p. 11, doi: <http://dx.doi.org/10.3390/sym10010011>.

- [31] M. Turkoglu, D. Hanbay, and A. Sengur, 2019. Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests, *J. Ambient Intell. Humaniz. Comput.*, doi: 10.1007/s12652-019-01591-w.
- [32] M. Khan, T. Akram, M. Sharif, K. Javed, M. Raza, and T. Saba, 2020. An Automated System for Cucumber Leaf Diseased Spot Detection and Classification using Improved Saliency Method and Deep Features Selection, *Multimed. Tools Appl.*, vol. 79, doi: 10.1007/s11042-020-08726-8.
- [33] S. Rajora, D. kumar Vishwakarma, K. Singh, and M. Prasad, 2018. CSgI: A Deep Learning based approach for Marijuana Leaves Strain Classification, in *2018 IEEE 9th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, pp. 209–214, doi: 10.1109/IEMCON.2018.8615011.
- [34] Z. Iqbal, M. A. Khan, M. Sharif, J. H. Shah, M. H. ur Rehman, and K. Javed, 2018. An automated detection and classification of citrus plant diseases using image processing techniques: A review, *Comput. Electron. Agric.*, vol. 153, pp. 12–32, doi: <https://doi.org/10.1016/j.compag.2018.07.032>.
- [35] H. T. Rauf, B. A. Saleem, M. I. U. Lali, M. A. Khan, M. Sharif, and S. A. C. Bukhari, 2019. A citrus fruits and leaves dataset for detection and classification of citrus diseases through machine learning, *Data Br.*, vol. 26, p. 104340, doi: <https://doi.org/10.1016/j.dib.2019.104340>.
- [36] S. Xing, M. Lee, and K. Lee, 2019. Citrus Pests and Diseases Recognition Model Using Weakly Dense Connected Convolution Network, *Sensors*, vol. 19, no. 14, doi: 10.3390/s19143195.
- [37] Q. Chen et al., 2019. Deep Convolutional Network for Citrus Leaf Diseases Recognition.
- [38] M. Sharif, M. A. Khan, Z. Iqbal, M. F. Azam, M. I. U. Lali, and M. Y. Javed, 2018. Detection and classification of citrus diseases in agriculture based on optimized weighted segmentation and feature selection, *Comput. Electron. Agric.*, vol. 150, pp. 220–234, doi: <https://doi.org/10.1016/j.compag.2018.04.023>.
- [39] C. B. Wetterich, R. Felipe de Oliveira Neves, J. Belasque, and L. G. Marcassa, 2016. Detection of citrus canker and Huanglongbing using fluorescence imaging spectroscopy and support vector machine technique, *Appl. Opt.*, vol. 55, no. 2, pp. 400–407, doi: 10.1364/AO.55.000400.
- [40] Kaggle, 2020. Citrus Leaves Prepared, <https://www.kaggle.com/dtrilsbeek/citrus-leaves-prepared>.
- [41] V. Chouhan et al., 2020. A Novel Transfer Learning Based Approach for Pneumonia Detection in Chest X-ray Images, *Applied Sciences*, vol. 10, no. 2., doi: 10.3390/app10020559.
- [42] A. G. Howard et al., 2017. Mobilenets: Efficient convolutional neural networks for mobile vision applications, *arXiv Prepr. arXiv1704.04861*.
- [43] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, 2018. Mobilenetv2: Inverted residuals and linear bottlenecks, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4510–4520.
- [44] S. Rajpal, N. Lakhyani, A. K. Singh, R. Kohli, and N. Kumar, 2021. Using handpicked features in conjunction with ResNet-50 for improved detection of COVID-19 from chest X-ray images, *Chaos, Solitons & Fractals*, vol. 145, p. 110749, doi: 10.1016/j.chaos.2021.110749.
- [45] S. Vallabhajosyula, V. Sistla, and V. K. K. Kolli, 2021. Transfer learning-based deep ensemble neural network for plant leaf disease detection, *J. Plant Dis. Prot.*, doi: 10.1007/s41348-021-00465-8.
- [46] D. M. Bulanon, T. F. Burks, D. G. Kim, and M. A. Ritenour, 2013. Citrus black spot detection using hyperspectral image analysis, *Agric. Eng. Int. CIGR J.*, vol. 15, no. 3, pp. 171–180.
- [47] D. Kim, T. F. Burks, M. A. Ritenour, and J. Qin, 2014. Citrus black spot detection using hyperspectral imaging, *Int. J. Agric. Biol. Eng.*, vol. 7, no. 6, pp. 20–27, doi: 10.3965/j.ijabe.20140706.004.
- [48] M. Zhang and Q. Meng, 2011. Automatic citrus canker detection from leaf images captured in field, *Pattern Recognit. Lett.*, vol. 32, no. 15, pp. 2036–2046, doi: <https://doi.org/10.1016/j.patrec.2011.08.003>.
- [49] D. Xiaoling, Y. Lan, X. Xiaqiong, M. Huilan, L. Jiakai, and H. Tiansheng, 2016. Detection of citrus Huanglongbing based on image feature extraction and two-stage BPNN modeling, *Int. J. Agric. Biol. Eng.*, vol. 9, no. 6, pp. 20–26.



- [50] X. Deng et al., 2020. Detection of Citrus Huanglongbing Based on Multi-Input Neural Network Model of UAV Hyperspectral Remote Sensing, *Remote Sensing* , vol. 12, no. 17., doi: 10.3390/rs12172678.