



# Domates Yapraklarında Hastalık Tespiti İçin Transfer Öğrenme Metotlarının Kullanılması

## Use of Transfer Learning Methods for Disease Detection in Tomato Leaves

<sup>1</sup>Serhat KILIÇARSLAN , <sup>2</sup>İshak PAÇAL 

<sup>1</sup>Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bandırma/Balıkesir, Türkiye

<sup>2</sup>Iğdır Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Merkez, Iğdır/Türkiye

<sup>1</sup>skilicarslan@bandirma.edu.tr, <sup>2</sup>ishak.pacal@igdir.edu.tr

Araştırma Makalesi/Research Article

### ARTICLE INFO

#### Article history

Received : 30 March 2023

Accepted : 15 May 2023

#### Keywords:

Tomato leaf disease detection, Plant disease detection, Leaf classification, Transfer learning

### ABSTRACT

Tomato consumption per capita worldwide is in the first place with approximately 20 kg per year. For this reason, the detection of diseases that may occur in tomato production is of great importance for producers. Since most of the diseases are based on tomato leaves, a healthy tomato leaf will increase the productivity of the products to be obtained and, as a result, a high harvest. Therefore, early and rapid detection of diseases that may occur in tomato leaves is of great importance in tomato production. In this study, DenseNet, ResNet50 and MobileNet architectures were used to detect diseases in tomato leaves. In order to compare the experimental results, an evaluation was made by considering the error, accuracy, precision, f1-score and sensitivity criteria. In the experimental results, the best performance was achieved with the DenseNet model, and 0.0269 error, 0.9900 accuracy, 0.9880 precision, 0.9892 f1-score and 0.9906 sensitivity results were obtained, respectively. According to the experimental results, deep learning models have been shown to offer high performance and reliability in the classification of tomato leaf diseases.

© 2023 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

### MAKALE BİLGİSİ

#### Makale Tarihleri

Gönderim : 30 Mart 2023

Kabul : 15 Mayıs 2023

#### Anahtar Kelimeler:

Domates yaprağı hastalığı tespiti, Bitki hastalık tespiti, Yaprak Sınıflandırma, Transfer öğrenme

### ÖZET

Dünya genelinde kişi başı domates tüketimi, yılda yaklaşık olarak 20 kg ile ilk sıralarda yer almaktadır. Bu nedenle domates üretiminde oluşabilecek hastalıkların tespiti üreticiler için büyük önem arz etmektedir. Hastalıkların çoğu domates yaprağı temelli olduğu için, domates yaprağının sağlıklı olması, elde edilecek ürünlerin verimliliğinin artması ve sonuç olarak yüksek bir hasat getirir. Bu yüzden domates yaprağında oluşabilecek hastalıkların erken ve hızlı şekilde tespit edilmesi, domates üretiminde büyük bir önem arz etmektedir. Bu çalışmada, domates yaprağında meydana gelen hastalıkları tespit edebilmek için DenseNet, ResNet50 ve MobileNet mimarileri kullanılmıştır. Deneysel sonuçların karşılaştırılması için hata, doğruluk, kesinlik, f1-skor ve duyarlılık metrikleri dikkate alınarak değerlendirme yapılmıştır. Deneysel sonuçlarda en iyi performans DenseNet modeli ile sağlanmış ve sırasıyla 0.0269 hata, 0.9900 doğruluk, 0.9880 kesinlik, 0.9892 f1-skor ve 0.9906 duyarlılık sonuçları elde edilmiştir. Deneysel sonuçlara göre derin öğrenme modelleri domates yaprağı hastalıklarının sınıflandırılmasında yüksek bir başarı ve güvenilirlik sunduğu görülmüştür.

© 2023 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

## 1. GİRİŞ

Dünya nüfusunun hızla artması ve kentleşmeden kaynaklı olarak, tarım alanlarının ve kişi başına düşen su gibi doğal kaynakların azalmaktadır. Bu nedenle tarımsal üretimde verimliliği artırmak için teknolojik ve genetik yöntemlerin kullanılması zorunlu hale gelmiştir. Domates, yılda kişi başına yaklaşık olarak 20 kg tüketimi ile toplam sebze tüketiminin yaklaşık %20'sini temsil etmektedir. Domates üretimi dünya genelinde Türkiye, Mısır, Çin gibi domates üreticilerinde ilk sırada yer alan sebze mahsulüdür [1]. Bitki verimliliğini etkileyen en önemli faktörlerden biri bitki hastalıklarıdır. Punjab ve Sindh'ın gerçekleştirdikleri araştırmalarda, domates yaprağının hastalanması sonucunda %30-%40 arasında bir ürün kaybı olduğunu ifade etmişlerdir. Bitki hastalıklarının zamanında tespit edilip önlenememesi, bitki veriminde ve kalitesinde önemli düşüşlere yol açmakta ve yetiştiriciler için önemli ekonomik kayıplara neden olmaktadır. Bu durum ayrıca, fahiş fiyatlarla domates ithal etme ihtiyacına yol açacaktır. Bu nedenle, bitki hastalık türlerinin hızlı ve doğru bir şekilde belirlenmesi ve hastalık şiddetinin değerlendirilmesi, zamanında önleme ve yönetim stratejilerinin uygulanması için esastır. Böylece ürün hastalıklarının erken tespiti ve kontrolü çiftçiler ve hassas tarım araştırmacıları için üretim kayıplarını azaltmak çok önemli bir süreçtir. Mevcut çiftlik uygulamaları, mikroskop gibi ek kaynaklar ve araçlar kullanan uzmanların desteğiyle çiftlik personeli tarafından bitki hastalıklarının görsel olarak tanımlanmasına dayanmaktadır. Ancak, tarım uzmanları, kapsamlı izleme yapmak için sahada sürekli olarak bulunamaz ve çiftçiler, tespit prosedürünü yürütmek için gereken uzmanlığa sahip değildir. Bundan dolayı, domates yaprağındaki hastalığın tespit edilebilmesi için, literatürde derin öğrenme yöntemleri yaygın şekilde kullanılmaktadır [2], [3].

Günümüzde, domates yaprağındaki hastalığın belirlenip doğru şekilde teşhis edilmesi hem uzun hem de zor bir süreçtir. Ayrıca, göz ile domates yaprağında meydana gelen hastalık türünün tespit edilmesi bu alandaki bilgi ve tecrübeye bağlıdır. Bundan dolayı, çalışmada domates yaprağındaki hastalıkların tespit edilebilmek üzere transfer öğrenme modellerinden DenseNet, ResNet50v2 ve MobileNet kullanılmıştır.

Literatürde, domates yaprağı hastalığının tespit edilmesi üzerine gerçekleştirilen çalışmalarda, YOLO, VGG-16, Faster R-CNN, ResNet, AlexNet, CNN, MobileNet gibi yöntemler kullanılmıştır [4]–[13]. Ayrıca, domateslerde hastalık tanımlaması ile ilgili olarak rengine, dokusuna, yaprakların şekline odaklanılarak sınıflandırılması üzerine çalışmalar gerçekleştirilmiştir [14]–[18]. Cengil ve Çıkar'ın yaptıkları çalışmada, Taiwan veri kümesi üzerinden domates yaprağı hastalığının tespiti için, transfer öğrenme modellerinden AlexNet, ResNet50 ve VGG16 kullanılmıştır. Deneysel sonuçlar doğrultusunda, en iyi başarımın ResNet50 modeli ile 0.9610'luk elde edildiğini bildirmişlerdir [13]. Adhikari ve arkadaşları, PlantVillage veri kümesi üzerinden üç sınıflı domates yaprağı hastalığını tespit edebilmek için YOLO modeli ile 0.7600'lik başarı elde edilmiştir [4]. Tm ve arkadaşları, domates yaprağı hastalığını tespit edebilmek için 18160 adet 2 sınıflı görüntüler üzerinden CNN tabanlı LeNet modeli kullanmışlardır. Deneysel değerlendirme sonucunda LeNet ile 0.9500'lik başarı elde ettiklerini bildirmişlerdir [19]. Mim ve arkadaşları, domates yaprağı hastalığını tespit edebilmek için sekiz katmanlı CNN mimarisi kullanmışlardır. Deneysel değerlendirmede yaklaşık olarak 6000 adet domates yaprağı görüntüsü üzerinden sınıflandırma gerçekleştirilmiş olup, 0.9655'lik başarı oranı elde ettiklerinin bildirmişlerdir [20]. Kushwaha ve Zade tarafından yapılan çalışmada, domates yaprağı hastalığını tespit etmek için 11000 adet 10 sınıflı görüntüler üzerinden hibrit derin öğrenme modeli geliştirmişlerdir. Geliştirilen hibrit derin öğrenme yöntemi ile %85'e yakın başarı elde ettiklerini bildirmişlerdir [21]. Alkaff ve Prasetiyo tarafından yapılan çalışmada, domates yaprağı hastalığını tespit etmek için 11000 adet 10 sınıflı görüntüler üzerinden CNN mimarisi kullanılarak gerçekleştirilmiştir. Kullanılan CNN modelinin Hyberband metodu kullanılarak hiper-parametre optimizasyonu yapıldıktan sonra deneysel değerlendirme gerçekleştirilmiştir. Deneysel değerlendirme sonucu olarak hiper-parametreleri optimize edilmiş CNN ike %88.50 başarı elde ettiklerini bildirmişlerdir [22]. Peyal ve arkadaşlarının yaptıkları çalışmada, Taiwan veri kümesi üzerinden domates yaprağı hastalığının tespiti için, transfer öğrenme modellerinden VGG-16, VGG-19 ve Inception-V3 kullanılmıştır. Deneysel sonuçlar doğrultusunda, en iyi başarımın Inception-V3 modeli ile %90 başarı elde edildiğini bildirmişlerdir [23]. Önerilen derin öğrenme yöntemlerinin literatürde aynı konuda yapılan çalışmalarla karşılaştırmalı sonuçları Tablo 1'de gösterilmiştir.

Bu çalışmada, bitki verimliliğini etkileyen en önemli faktörlerden biri olan bitki hastalıklarının erken şekilde teşhis edilmesidir. Bitki hastalıklarının zamanında tespit edilip önlenememesi, bitki veriminde ve kalitesinde önemli düşüşlere yol açmakta ve yetiştiriciler için önemli ekonomik kayıplara neden olmaktadır. Bu doğrultuda, Kaggle platformu üzerinden elde edilen 11000 örnek ve 10 sınıflı veri kümesi üzerinden domates yaprağı hastalık teşhisini için deneysel analizler gerçekleştirilmiştir. Deneylerde, DenseNet, ResNet50v2 ve MobileNet modelleri kullanılarak performansları karşılaştırılmıştır. Analizler sonucunda, DenseNet modelinin diğer yöntemlere göre daha iyi performans sergilediği gözlemlenmektedir. Bu çalışmanın temel motivasyonu, domates yaprağı hastalığının sınıflandırılması için transfer öğrenme yöntemleri kullanılmış olup, hastalığın erken teşhisinde başarılı sonuçlara ulaşmaktır. Çalışmanın ana katkıları;

- Son zamanlarda geliştirilen domates yaprak hastalığının sınıflandırılması ve tanımlanması yaklaşımlarının incelenmesi ve değerlendirilmesi gerçekleştirilmiştir.
- Önerilen çalışmanın sınıflandırma doğruluğunu iyileştirmek için aktivasyon fonksiyonu, epoch sayısı, optimizasyon ve öğrenme oranı gibi hiper-parametrelerin optimizasyonu gerçekleştirilerek deneysel değerlendirmeler yapılmıştır.

- Eğitilen derin öğrenme yöntemleri kullanılarak erken domates yaprağı hastalığının tespiti, hastalıkların zararlı etkilerini azaltabilir ve sürekli insan denetiminin dezavantajlarıyla da başa çıkmamıza olanak tanınması sağlanmıştır.

**Tablo 1.** Domates yaprağı hastalığı ile ilgili literatürün karşılaştırılması.

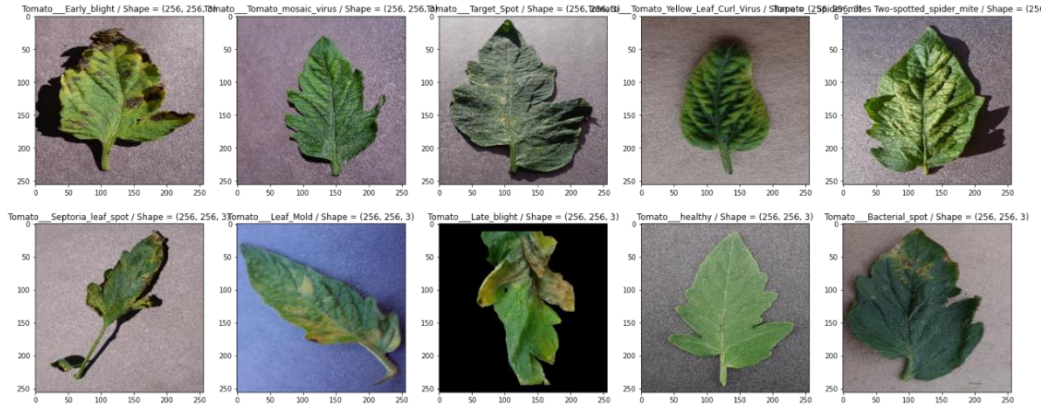
Yayınlar	Yıl	Metot	Doğruluk
[4]	2018	YOLO	0.7600
[5]	2017	VGG16	0.8500
[7]	2018	ResNet	0.9728
[8]	2020	CNN	0.9800
[9]	2020	CNN	0.9120
[10]	2017	AlexNet	0.9565
[11]	2019	MobileNet	0.9030
[20]	2018	CNN	0.9655
[19]	2019	LeNet	0.9500
[21]	2022	Hibrit CNN	0.8800
[22]	2022	CNN	0.8850
[23]	2021	Inception-V3	0.9000

Çalışmanın ikinci bölümünde domates hastalığı veri kümesi ve kullanılan yöntemler verilmiştir. Üçüncü bölümde, deneysel değerlendirme sonuçları ve tartışma verilmiştir. Son bölümde ise sonuçlar ve gelecek çalışmalar sunulmaktadır.

## 2. MATERYAL VE METOD

### 2.1. Domates Yaprığı Hastalığı Veri Kümesi

Domates, dünyanın en önemli meyveleri arasındadır. Domates üretimi dünya genelinde Türkiye, Mısır, Çin gibi domates üreticilerinde ilk sırada yer alan sebze mahsulüdür [1]. Domates, çeşitli mantar, bakteriyel, viral hastalıklardan ciddi şekilde etkilenir ve semptomlar bitkinin farklı kısımlarında yaprak, gövde, meyve gibi alanlarda görülebilir. Bu çalışmada, Kaggle platform üzerinden elde edilen PlantVillage [24], [25] veri kümesi kullanılmıştır. Çalışmada kullanılan veri kümesi, 11000 örnek ve 9 hastalıklı yaprak sınıfı ve 1 sağlıklı yaprak sınıf bilgisine sahip görüntülerden oluşmaktadır. Şekil 1'de yer alan sınıflar, farklı hastalıklı domates yaprakları örneklerinden bazılarıdır. Böylece, bu verilere dayanarak, Derin Öğrenme modellerinden DenseNet, ResNet50v2 ve MobileNet kullanılarak araştırma yapıldı ve bitki hastalıkları belirlendi.



**Şekil 1.** Sağlıklı ve hastalıklı domates yaprağı görüntüleri.

Şekil 1'de görülen görüntülerde semptomlar solgunluk, çürüklük, meyvelerde lekeler, yapraklarda renk değişikliğinden bodur büyümeye kadar değişiklik gösterir. Çalışmada kullanılan veri kümesi 9000 örnek eğitim, 1000 örnek doğrulama ve 1000 örnek test olarak bölünmüştür. Tablo 2'de, kullanılan veri kümesine ait çeşitli resimlerin ve sınıflarının adlarının kapsamlı bir tasviri gösterilmiştir. Bu görüntüler, verileri eğitmek, test etmek ve doğrulamak için veri kümesinde bulunur.

### 2.2. Derin Öğrenme Yöntemleri

Makine öğreniminin popüler bir alt dalı olan derin öğrenme, büyük veri ve bilgisayar işlem gücü kullanan yapay sinir ağlarına dayalı bir yaklaşımdır. Derin öğrenmenin temelleri geçmişe dayansa da yükselişi son yıllarda olmuştur. Özellikle, bilgisayar dünyasındaki büyük miktardaki veri ve grafik işlem birimlerinin (GPU'lar) artmasıyla birlikte ve buna ek olarak GPU'ların ekonomik bir çizgiye dönmesi ile derin öğrenme yaklaşımları hızlı bir yükseliş trendi yakalamıştır [26]. Derin öğrenmede, matris ve veri işleme birimlerindeki asıl işlemlerin

yürütülmesi GPU'lar sayesinde olur. GPU'lar ise aynı anda birden çok işlemi ve hesaplamayı gerçekleştirme yeteneğine sahiptir. Derin öğrenme yaklaşımları, verileri alırken ve analiz ederken herhangi bir insan müdahalesi gerektirmez. Böylece klasik makine öğrenimi yaklaşımlarından basitçe ayrılırlar. Derin öğrenmenin temelinde yatan en önemli unsurlardan bir tanesi özellik çıkarımını otomatik olarak gerçekleştirerek üst düzey özneliklerin keşfedilmesini sağlar [27]. Böylece gerçek zamanlı işlem yapabilme özelliği ile popüler bir yer edinmiştir. Klasik makine yöntemlerinden olan destek vektör makinesi (DVM), karar ağacı ve lojistik regresyon gibi yapılar basit ve az veri gerektiren problemlere iyi bir çözüm sunar ancak problem karmaşıklığı veya veri arttıkça bu yapılar bir darboğaz yaşarlar ve genelleme yapma yeteneğinden yoksun olurlar. Öte yandan derin öğrenme yaklaşımları, klasik makine öğrenmesi yaklaşımlarının karşılaştığı bu sorunları iyi çözer ve verileri hiyerarşik düzeyde iyi bir şekilde ele alır ve soyutlar. Böylece verileri daha iyi temsil ederler, aynı zamanda güçlü bir genelleme ile yüksek bir uyum sağlama yeteneğine sahiptirler.

**Tablo 2.** Veri kümesine ait kapsamlı özellikleri.

Sınıflar	Eğitim Görüntüleri	Test Görüntüleri	Doğrulama Görüntüleri	Toplam Görüntüler
Tomato Bacterial spot	900	100	100	1100
Tomato Early blight	900	100	100	1100
Tomato Late blight	900	100	100	1100
Tomato Leaf Mold	900	100	100	1100
Tomato Septoria leaf spot	900	100	100	1100
Tomato Spider Mites Two spotted spider mite	900	100	100	1100
Tomato Target Spot	900	100	100	1100
Tomato Yellow Leaf Curl Virus	900	100	100	1100
Tomato mosaic virus	900	100	100	1100
Tomato healthy	900	100	100	1100
<b>Toplam</b>	<b>9000</b>	<b>1000</b>	<b>1000</b>	<b>11000</b>

Derin öğrenme yaklaşımları, verilerin etiketli ve etiketsiz olma duruma göre sınıflandırılır [28]–[34]. Verinin etiketli bir formu varsa o zaman denetimli öğrenme, etiketsiz bir formu olursa o zaman ise denetimsiz öğrenme ve son olarak ise hem etiketli hem de etiketsiz veri kullanılıyorsa yarı denetimli öğrenme diye sınıflandırılır. CNN'ler, RNN'ler ve bunların türetilmiş yapıları, denetimli derin öğrenme ağları kısmını oluşturur. Diğer taraftan ise AE, DBN, RBM gibi derin öğrenme ağları ise denetimsiz öğrenme sınıfında yer alırlar. Ayrıca bu ağların hibrit ve karma form yapıları da kullanılabilir. Ele alınan problemin veri seti, özellikleri ve kısıtları dikkate alınarak çözüm için en uygun derin öğrenme ağı ve modelinin seçilmesi en uygun çözümü sunması beklenmektedir [27], [28], [35], [36].

### 2.3. Sınıflandırma için Modeller

Derin öğrenme mimarileri literatürde yaygın olarak, görüntü işleme, zaman serisi analizi, sınıflandırma gibi birçok alanda yaygın olarak kullanılmaktadır [28], [29], [37]–[39]. Bu çalışmada, domates hastalıklarını sınıflandırmak için en popüler mimarilerden olan ResNet, MobileNet ve DenseNet kullanılmıştır. Modellerin daha hızlı bir yakınsama ile yüksek bir başarımla göstermesi için öğrenme aktarımı (transfer learning) ve veri artırma teknikleri kullanılmıştır. Transfer öğrenme için ImageNet veri seti üzerinde eğitilen modellerin ön-eğitilmiş ağırlıkları kullanılmıştır. Veri artırma tekniği olarak ise en temel tekniklerden olan döndürme, çevirme ve ölçekleme işlemleri uygulanmıştır.

**ResNet:** Artık Sinir Ağı mimarisi yani kısa adıyla ResNet, 2016 yılında Microsoft araştırma ekibi tarafından önerilen güçlü bir CNN mimarisidir. ResNet'i diğer mimarilerden ayıran özelliklerin başında atlama ya da atık katmanlarının kullanılması gelmektedir. Yani, birkaç tane katman eğitime girmeden atlanır ve doğrudan çıkış sınıfına bağlanmış olmaktadır. Bu da kaybolan gradyan probleminin giderilmesine yardımcı olmaktadır.

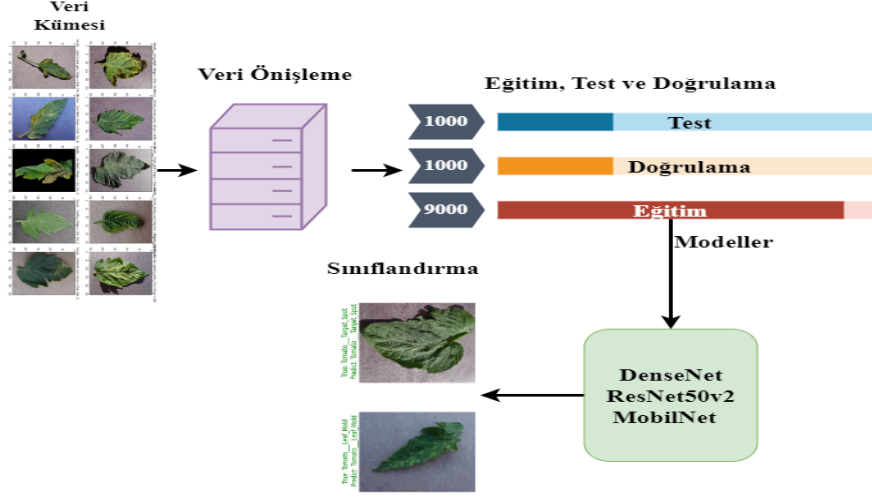
**MobileNet:** Bu ağ, diğer ağlara göre hesaplama açısından yani GPU yükü açısından oldukça verimli bir mimaridir. MobileNet, özellikle gerçek dünya uygulamaları için oldukça tercih edilen bir ağıdır. Bunun temel nedeni ise daha az hesaplama yükü getirmesi ve böylece gerçek zamanlı uygulamalar için daha popülerdir. MobileNet derinlemesine ayrılabilir konvolüsyonlar kullanmaktadır. Aynı derinliğe sahip düzenli evrişimlere sahip ağlara kıyasla parametre sayısını önemli ölçüde azaltır, bu da daha hafif derin sinir ağları yani bu ağı meydana getirmektedir.

**DenseNet:** CNN mimarilerinde, ağ girişine yakın katmanlar ile çıkışa yakın katmanlar arasında daha kısa bağlantılar olduğu zaman ağ daha derin bir yapıya ve yeterli veri seti ile daha etkili ve verimli çalışır. Yoğun Evrişimli Ağ (DenseNet) modeli, ResNet'e benzer bir yapıdadır ve özellikle büyük sinir ağlarında kaybolan gradyan problemini çözmek için tanıtılan başarılı bir derin öğrenme mimarisidir. ResNet'te katmanın çıktısı özellik haritaları toplanırken, DenseNet'te ise bunlar birleştirilir. Ayrıca, DenseNet her katmanı diğer tüm katmanlara ileri beslemeli bir şekilde bağlar. Ağ, özellik haritalarının boyutunun sabit kaldığı, ancak filtre sayısının değiştiği Yoğun Bloklardan oluşur. Geçiş Katmanları olarak adlandırılan filtreler, toplu normalleştirme, çekirdek 1x1 ile bir evrişim ve çekirdek 2x2 ile bir havuzlama katmanı ile alt örneklemeden sorumludur. Yoğun bir Ağda, her katmanın önceki özellik haritalarına erişimi vardır. Dolayısıyla, her katman bu kolektif bilgiye yeni bilgiler ekliyor. Modelin DenseNet121, DenseNet160 ve DenseNet201 gibi farklı versiyonları bulunmaktadır. Bu

çalışmada ImageNet ağırlığı üzerinde eğitilen DenseNet-121 modeli kullanılmıştır. ImageNet veri seti üzerinde eğitilen ağırlıkların kullanılması sayesinde, modelin yakınıması daha kısa sürede olmakla beraber, aynı zamanda modelin daha yüksek bir başarıyı göstermesine olanak sağlamaktadır.

### 3. DENEYSEL SONUÇLAR VE TARTIŞMA

Bu çalışma, Windows 10 üzerinde çalışan Intel (R) Core (TM) i5-10400 CPU@2.90 GHz ve 8 GB RAM'e sahip dizüstü bilgisayar üzerinde Spyder 3.10.8 Python geliştirme ortamında gerçekleştirilmiştir. Domates yaprağı hastalığının tespiti için geliştirilen karar destek sistemi Şekil 2'de gösterilmektedir.



Şekil 2. Özet diyagram.

Çalışmada, modelimizin daha verimli olması için 0,2 rastgele döndürme ve büyütme gerçekleştirmek için yatay olan rastgele çevirme (horizontal and vertical) uyguladık. Görüntüler çeşitli açılarda ve konumlarda değiştirilmesi sayesinde, daha iyi bir veri sınıflandırması elde edildi. Ayrıca, önceden eğitilmiş DenseNet, ResNet50v2 ve MobileNet modelleri iki katman olarak kullanıldı. İlk katman için, DenseNet, ResNet50v2 ve MobileNet için önceden eğitilmiş ImageNet ağırlıkları içe aktarıldı. İkinci katman olarak GlobalAveragePooling2D katmanı uygulanmıştır. Tam bağlantı katmanı 1000 nöron ve sınıflandırma katmanı olarak softmax tercih edilmiştir. Ayrıca deneysel değerlendirmelerde optimizör olarak SGD tercih edilmiştir. Kullanılan veri seti üzerinden eğitim sürecini hızlandırmak ve modelin eğitimini hesaplamada uygulanabilir kılmak için görüntüler 224×224 olarak yeniden boyutlandırıldı.


Çalışmada, domates yaprağı hastalığını tespit edebilmek için kullanılan DenseNet, ResNet50v2 ve MobileNet modellere ait hata, doğruluk, duyarlılık, kesinlik ve f1-skor kriterlerinin deneysel değerlendirme sonuçları Tablo 3'te sunulmuştur. Şekil 3 ve 4'te görüldüğü gibi deneysel değerlendirme amacıyla kullanılan yöntemlerine hata ve doğruluk grafikleri görülmektedir. Deneysel sonuçlar her bir model için 20 epok eğitilmiştir.

Tablo 3. Deneysel sonuçlar.


Modeller	Hata	Doğruluk	Duyarlılık	Kesinlik	F1-Skor
DenseNet	0.0269	0.9900	0.9880	0.9906	0.9892
ResNet50v2	0.1511	0.9533	0.9513	0.9568	0.9540
MobileNet	0.2014	0.9317	0.9190	0.9481	0.9333

Tablo 3, domates yaprağı hastalığının teşhisi için DenseNet, ResNet50v2 ve MobileNet modelleri ile gerçekleştirilen deneysel sonuçlar sunulmuştur. Deneysel sonuçlarda en iyi performans değeri DenseNet modeli ile elde edildiği görülmektedir. Deneysel değerlendirmelerde DenseNet ile 0.9900 doğruluk, 0.9880 duyarlılık, 0.9906 kesinlik, 0.9892 f1-skor ve 0.0269 hata değerleri elde edilmiştir. Ayrıca MobileNet modelinin 0.9317 doğruluk, 0.9190 duyarlılık, 0.9481 kesinlik, 0.9333 f1-skor ve 0.2014 hata ile en düşük başarımın elde edildiği görülmüştür.


Şekil 3 ve 4 incelendiğinde, hata ve doğruluk grafikleri gözlemlenmektedir. Gerçekleştirilen domates yaprağı hastalığını tespit etmek üzere gerçekleştirilen deneysel değerlendirmelerde, önerilen yöntemin diğer transfer öğrenme yöntemlerine göre daha başarılı sonuçlar elde ettiği gözlemlenmektedir. Şekil 3'de DenseNet modeli, deneysel değerlendirme sürecinin başından sonuna kadar en küçük hata oranı ile çalıştığı gözlemlenmektedir. Ayrıca Şekil 4 incelendiğinde, DenseNet modeli eğitim süreci boyunca en yüksek başarı oranı ile çalıştığı görülmektedir. Şekil 5'te en iyi başarı oranı elde edilen DenseNet modeline dair test verisinin karışıklık matrisi verilmiştir. Şekil 5'te domates yaprağı hastalıklarına ait 10 sınıflı test veri kümesine ait karışıklık matrisi gözlemlenmektedir.



Şekil 3. Deneysel değerlendirme sonuçlarından hata grafiği.



Şekil 4. Deneysel değerlendirme sonuçlarından doğruluk grafiği.



Şekil 5. En iyi başarıyı veren DenseNet modelinin test verisi karışıklık matrisi.

Şekil 5'te, Spidermites Two-spottedspider\_mite ve TomatoYellowLeafCurlVirus sınıfları hariç diğer tüm sınıflarda yüksek oranda başarı ile sınıflandırdığı gözlemlenmektedir. Böylece önerilen yöntemin başarılı sonuçlar elde edebildiği sonucuna varılabilmektedir.

Yapılan tüm deneysel değerlendirmede DenseNet modeli ile en iyi başarı elde edildiği görülmektedir. Modeller hata, doğruluk, duyarlılık, kesinlik ve f1-skor performans değerlendirme ölçütlerine göre değerlendirilmiştir. Derin öğrenme yöntemleri bitki hastalıklarının teşhisinde yaygın olarak kullanılmaktadır. Bu yöntemler sayesinde, domates yaprağındaki hastalığın erken teşhis edilerek, bitki veriminin ve kalitesinin artırılması sağlanmış olmaktadır.

#### 4. SONUÇ

Bitki hastalıklarının zamanında tespit edilip önlenememesi, bitki veriminde ve kalitesinde önemli düşüşlere yol açmakta ve yetiştiriciler için önemli ekonomik kayıplara neden olmaktadır. Ayrıca, bitki hastalıklarının göz ile denetimi hataya açık ve çok zahmetli olmaktadır. Derin öğrenme algoritmaları kullanılarak erken domates yaprağı hastalığının tespiti, hastalıkların zararlı etkilerini azaltabilir ve sürekli insan denetiminin dezavantajlarıyla da başa çıkmamıza imkân tanımaktadır. Bu çalışmada, domates yaprağı hastalığının teşhisi için derin öğrenme

modellerinden DenseNet, ResNet50v2 ve MobileNet kullanılmıştır. Deneysel değerlendirme sonucunda en iyi başarımın DenseNet ile 0.9900 doğruluk, 0.9880 duyarlılık, 0.9906 kesinlik, 0.9892 f1-skor ve 0.0269 hata değerleri elde edilmiştir. Deneylede önerilen DenseNet modelin mimarisi, domates yaprak hastalıklarının sınıflandırılmasında yüksek sonuçlar vermiştir. Ek olarak, Spidermites Two-spottedspider\_mite ve TomatoYellowLeafCurlVirus sınıfları hariç diğer tüm sınıflarda yüksek oranda başarı ile sınıflandırdığı gözlemlenmektedir. Böylece önerilen yöntemin başarılı sonuçlar elde edebildiği sonucuna varılabilmektedir. Bu modelin performansı, sunulan literatür çalışmalarından daha iyi performans göstermiştir. Kullanılan veri seti gürültüsüz yüksek kaliteli görüntülerden oluşmaktadır. Sistemi gerçek zamanlı olarak daha sağlam hale getirmek için gelecekte akıllı telefon aracılığıyla çekilen görüntüler üzerinde yeniden eğitim yapılmalıdır.

## Yazar Katkıları

Yazar çalışmaya eşit oranlı katkı sunmuştur.

## Çıkar Çatışması

Makale yazarları, aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

## KAYNAKÇA

- [1] S. Zhao, Y. Peng, J. Liu, ve S. Wu “Tomato leaf disease diagnosis based on improved convolution neural network by attention module”, *Agriculture*, vol. 11, no 7, pp. 651, 2021.
- [2] S. Mansoor vd., “Evidence for the association of a bipartite geminivirus with tomato leaf curl disease in Pakistan”, *Plant Dis.*, vol. 81, no. 8, pp. 958-958, 1997.
- [3] A. Raza vd., “First report of tomato chlorosis virus infecting tomato in Pakistan”, *Plant Dis*, vol. 104, no. 2036, pp. 10-1094, 2020.
- [4] S. Adhikari, D. Unit, B. Shrestha, ve B. Baiju, “Tomato Plant Diseases Detection System”, 1st KEC Conference Proceedings, pp. 81-86, 2018.
- [5] A. Fuentes, S. Yoon, S.C. Kim, ve D.S. Park “A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition”, *Sensors*, vol. 17, no. 9, pp. 2022, 2017.
- [6] B.A. Ashqar ve S.S. Abu-Naser “Image-based tomato leaves diseases detection using deep learning”, 2018.
- [7] S. Zhao, Y. Peng, J. Liu, ve S. Wu “Tomato leaf disease diagnosis based on improved convolution neural network by attention module”, *Agriculture*, vol. 11, no. 7, p. 651, 2021.
- [8] R. Karthik, M. Hariharan, S. Anand, P. Mathikshara, A. Johnson, ve R. Menaka “Attention embedded residual CNN for disease detection in tomato leaves”, *Appl. Soft Comput.*, vol. 86, p. 105933, 2020.
- [9] M. Agarwal, A. Singh, S. Arjaria, A. Sinha, ve S. Gupta “ToLeD: Tomato leaf disease detection using convolution neural network”, *Procedia Comput. Sci.*, vol. 167, pp. 293-301, 2020.
- [10] H. Durmuş, E.O. Güneş, ve M. Kırıcı “Disease detection on the leaves of the tomato plants by using deep learning”, 6th International conference on agro-geoinformatics, IEEE, pp. 1-5, 2017.
- [11] A. Elhassouny ve F. Smarandache “Smart mobile application to recognize tomato leaf diseases using Convolutional Neural Networks”, *International Conference of Computer Science and Renewable Energies (ICCSRE)*, IEEE, pp. 1-4, 2019.
- [12] L.R. Burra, J. Bonam, P. Tumuluru, ve B. Narendra Kumar Rao “Fine-tuning for Transfer Learning of ResNet152 for Disease Identification in Tomato Leaves”, *In Intelligent Computing and Applications*, Springer Nature, pp. 295-302, 2022.
- [13] E. Cengil ve A. Çınar “Hybrid convolutional neural network based classification of bacterial, viral, and fungal diseases on tomato leaf images”, *Concurr. Comput. Pract. Exp.*, vol. 34, no. 4, p. e6617, 2022.
- [14] S. Widiyanto, D.T. Wardani, ve S.W. Pranata “Image-Based tomato maturity classification and detection using Faster R-CNN method”, 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), IEEE, pp. 130-134, 2021.
- [15] X. Zhou, P. Wang, G. Dai, J. Yan, ve Z. Yang “Tomato Fruit Maturity Detection Method Based on YOLOV4 and Statistical Color Model”, 11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER), IEEE, pp. 904-908, 2021.
- [16] C. S. Hlaing ve S. M. M. Zaw “Tomato plant diseases classification using statistical texture feature and color feature”, *IEEE/ACIS 17th International Conference on Computer and Information Science (ICIS)*, IEEE, pp. 439-444, 2018.
- [17] J. Lu, G. Shao, Y. Gao, K. Zhang, Q. Wei, ve J. Cheng “Effects of water deficit combined with soil texture, soil bulk density and tomato variety on tomato fruit quality: A meta-analysis”, *Agric. Water Manag.*, vol. 243, pp. 106427, 2021.
- [18] S. Kaur, S. Pandey, ve S. Goel “Plants disease identification and classification through leaf images: A survey”, *Arch. Comput. Methods Eng.*, vol. 26, pp. 507-530, 2019.
- [19] P. Tm, A. Pranathi, K. SaiAshritha, N.B. Chittaragi, ve S.G. Koolagudi “Tomato leaf disease detection using convolutional neural networks”, *Eleventh international conference on contemporary computing (IC3)*, IEEE, pp. 1-5, 2018.
- [20] T.T. Mim, M.H. Sheikh, R.A. Shampa, M.S. Reza, ve M.S. Islam “Leaves diseases detection of tomato using image processing”, 8th international conference

- system modeling and advancement in research trends (SMART), IEEE, pp. 244-249, 2019.
- [21] S. Kushwaha ve S. Zade "Identification of Tomato Leaf Disease Prediction Using CNN", Int. J., vol. 7, no. 8, pp. 36-41, 2022.
- [22] A.K. Alkaff ve B. Prasetyo "Hyperparameter Optimization on CNN Using Hyperband on Tomato Leaf Disease Classification", IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom), IEEE, pp. 479-483, 2022.
- [23] H.I. Peyal, S.M. Shahriar, A. Sultana, I. Jahan, ve M. H. Mondol "Detection of tomato leaf diseases using transfer learning architectures: A comparative analysis", International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI), IEEE, pp. 1-6, 2021.
- [24] D. Singh, N. Jain, P. Jain, P. Kayal, S. Kumawat, ve N. Batra "PlantDoc: a dataset for visual plant disease detection", Proceedings of the 7th ACM IKDD CoDS and 25th COMAD, pp. 249-253, 2020.
- [25] S.P. Mohanty, D. P. Hughes, ve M. Salathé "Using deep learning for image-based plant disease detection", Front. Plant Sci., vol. 7, pp. 1419, 2016.
- [26] I. Pacal, D. Karaboga, A. Basturk, B. Akay, ve U. Nalbantoglu "A comprehensive review of deep learning in colon cancer", Comput. Biol. Med., vol. 126, p. 104003, 2020.
- [27] A. Karaman vd. "Hyper-parameter optimization of deep learning architectures using artificial bee colony (ABC) algorithm for high performance real-time automatic colorectal cancer (CRC) polyp detection", Appl. Intell., pp. 1-18, 2022.
- [28] M.A. Bülbül, E. Harirchian, M.F. Işık, S.E. Aghakouchaki Hosseini, ve E. Işık "A Hybrid ANN-GA Model for an Automated Rapid Vulnerability Assessment of Existing RC Buildings", Appl. Sci., vol. 12, no. 10, 2022,
- [29] M.A. Bülbül, C. Öztürk, ve M.F. Işık "Optimization of Climatic Conditions Affecting Determination of the Amount of Water Needed by Plants in Relation to Their Life Cycle with Particle Swarm Optimization, and Determining the Optimum Irrigation Schedule", Comput. J., vol. 65, no. 10, 2022.
- [30] M.A. Bülbül "Kuru Fasulye Tohumlarının Çok Sınıflı Sınıflandırılması İçin Hibrit Bir Yaklaşım", J. Inst. Sci. Technol., vol. 13, no. 1, 2023.
- [31] K. Adem "Impact of activation functions and number of layers on detection of exudates using circular Hough transform and convolutional neural networks", Expert Syst. Appl., vol. 203, p. 117583, 2022.
- [32] K. Adem ve S. Kiliçarslan, "COVID-19 Diagnosis Prediction in Emergency Care Patients using Convolutional Neural Network", Afyon Kocatepe Üniversitesi Fen Ve Mühendis. Bilim. Derg., vol. 21, no. 2, 2021.
- [33] S. Kılıçarslan, A. Kemal, ve M. Çelik "An overview of the activation functions used in deep learning algorithms", J. New Results Sci., vol. 10, no. 3, pp. 75-88, 2021.
- [34] M. Hekim, O. Cömert, ve K. Adem "A hybrid model based on the convolutional neural network model and artificial bee colony or particle swarm optimization-based iterative thresholding for the detection of bruised apples", Turk. J. Electr. Eng. Comput. Sci., vol. 28, no. 1, pp. 61-79, 2020.
- [35] E. Dönmez "Enhancing classification capacity of CNN models with deep feature selection and fusion: A case study on maize seed classification", Data Knowl. Eng., vol. 141, p. 102075, 2022.
- [36] S. Kiliçarslan, C. Közkurt, S. Baş, ve A. Elen "Detection and classification of pneumonia using novel Superior Exponential (SupEx) activation function in convolutional neural networks", Expert Syst. Appl., vol. 217, p. 119503, 2023.
- [37] K. Adem, S. Kiliçarslan, ve O. Cömert "Classification and diagnosis of cervical cancer with stacked autoencoder and softmax classification", Expert Syst. Appl., vol. 115, pp. 557-564, 2019.
- [38] S. Kiliçarslan ve M. Celik "RSigELU: A nonlinear activation function for deep neural networks", Expert Syst. Appl., vol. 174, p. 114805, 2021.
- [39] I. Pacal ve D. Karaboga "A robust real-time deep learning based automatic polyp detection system.", Comput. Biol. Med., vol. 134, pp. 104519-104519, 2021.