

# Bitki Hastalıklarının Tespiti için Ön İşlemli Görsel Dönüştürücü Tabanlı bir Yaklaşım

## A Pre-Processed Visual Dönüştürücü Based Approach for Plant Disease Detection

Ferdi DOĞAN

Adıyaman Üniversitesi

Mühendislik Fakültesi

Adıyaman, Türkiye

fdogan@adiyaman.edu.tr

ORCID: 0000-0002-9203-697X

### Öz

İnsanlığın ihtiyaç duyduğu gıda miktarı, dünya nüfusuyla birlikte artmaktadır. Daha sağlıklı ve yüksek miktarda verim için bitkilerin sağlıklı yetiştirilmesi gerekmektedir. Bitkilerde oluşan hastalıklar ürün yetiştiriciliğindeki verimi düşürmektedir. Bu çalışma ile tarımsal verimliliği ve sürdürülebilirliği artırmak için gerekli olan bitki hastalıklarının tespiti konusu ele alınmaktadır. Çalışma, bitki hastalıklarının yüksek doğrulukla tespit etmek için derin öğrenme modelleri ve bölütlemeye dayalı Görsel Dönüştürücü (Vit 16B) modeli ile birleştirilmiş görüntü işleme tekniklerini kullanan yeni bir yöntem sunmaktadır. Modelin akıllı tarımda kullanılması, bitki hastalıkları ile mücadele için bitki hastalıklarının tespiti ve ekonomik açıdan yüksek verim alınmasını amaçlanmaktadır. Çalışmada önerilen modelin başarımı 8 farklı derin öğrenme (AlexNet, SqueezeNet, ResNet18, ResNet50, ResNet101, GoogleNet, Vgg16, Vgg19) modelleriyle karşılaştırılarak başarımı ortaya konmuştur. Önerilen modelin derin öğrenme modellerinden daha iyi başarımlar gösterdiği ve %99,87'lik bir doğruluk elde edildiği saptanmıştır. Her sınıf için tutturma, bulma ve F1 değeri değerlendirme ölçütleri ile başarımları ortaya konmuştur.

**Anahtar Sözcükler:** Derin Öğrenme, Görsel Dönüştürücü, Görüntü İşleme, Akıllı Tarım, Tarımsal Verimlilik, Bitki Hastalıkları

### Abstract

The amount of food needed by humanity is increasing along with the world population. For healthier and higher yields, plants need to grow healthy. Diseases that occur in plants reduce the yield in crop cultivation. This study addresses the detection of plant diseases, which is necessary to increase agricultural productivity and sustainability. The study presents a new method that uses image processing techniques combined with deep learning models and segmentation-based Vision Dönüştürücü (Vit 16B) model to detect plant diseases with high accuracy. The aim of the model is to use it in smart agriculture, to enable early and accurate plant disease detection and to obtain high economic efficiency. In the study, the performance of the proposed model was compared with 8 different deep learning (AlexNet, SqueezeNet, ResNet18, ResNet50, ResNet101, GoogleNet, Vgg16, Vgg19) models and its success was demonstrated. It was determined that the proposed model outperformed the deep learning models and achieved an accuracy of 99.87%. For each class, the performances are demonstrated with the evaluation metrics of precision, recall and F1 scores.

**Keywords:** Deep Learning, Vision Dönüştürücü, Image Processing, Smart Agriculture, Agricultural Productivity, Plant Disease

### 1. Giriş

Küresel nüfus arttıkça tarımsal gıdalara da ihtiyaçlar aynı oranda artmaktadır [1]. Nüfus artışına bağlı olarak gıda ihtiyaçlarını karşılayabilmek ve tarımsal üretim

#### Makale Bilgileri

Türü: Araştırma  
Geliş tarihi: 15.02.2025  
Düzeltilme tarihi: 31.10.2025  
Kabul tarihi: 31.10.2025

#### Article Info

Type: Research  
Received date: 15.02.2025  
Revision date: 31.10.2025  
Accepted date: 31.10.2025

**Atıf/ to Cite (IEEE):** F. DOĞAN, Bitki Hastalıklarının Tespiti için Ön İşlemli Görsel Dönüştürücü Tabanlı bir Yaklaşım: Bilgisayar Bilimleri ve Mühendisliği Dergisi, Cilt 19 2026 Sayı-19-1. Sf: 10-23,  
**DOI:**10.54525/bbmd.1640557

yöntemlerinde gelişim sağlamak amacıyla yenilikçi bir tarım politikası kaçınılmaz bir gereklilik haline gelmiştir. Bu bağlamda, ülkeler gıda ürünlerinin kalitesini ve verimliliğini artırmak için çeşitli tedbirler almaktadır. Bu tedbirlerin başında teknolojik yenilikler gelmekte olup, Endüstri 4.0 ile uyumlu şekilde Tarım 4.0 uygulamaları hayata geçirilmeye başlanmıştır [2]. Tarımda teknolojik gelişmeler, akıllı tarım uygulamaları, bilgi iletişim teknolojilerinin tarımsal alanlarda kullanılması yaygınlaşmıştır [3, 4].

Besin kaynaklarındaki verimin artırılmasındaki engellerden biri de yetiştirilen ürünlerdeki hastalıklardır. Bitkilerden elde edilen ürünlerdeki hastalık hasat oranını ve kalitesini azaltmaktadır[5]. Bitki hastalıklarının en belirgin özelliği yapraklarda vermiş olduğu tepkilerdir. Yaprığın şekli, yaprakta oluşan bozulmanın biçimi, yapraktaki renk değişimi, yaprak üzerindeki noktalı delikler yaprağın hastalığı hakkında bilgi vermektedir. Bu bilgiler ışığında bitkiye uygulanacak olan tedaviye göre bitki yaşamsal faaliyetlerini yerine getirmektedir. Bununla birlikte bitkiden elde edilen meyve miktarında artış gerçekleşmektedir. Bu durum sağlıklı bir bitkiden alınacak hasat miktarını ve hasat kalitesi ekonomik olarak değerli kılmaktadır[6]. Geleneksel yöntemler kullanılarak yaprak hastalıklarının tespit edilmesi tarım uzmanları tarafından yapılmakta ve bitki patojistlerin gözlemlenmesi ile gerçekleşmektedir. Uzmanlar bitki yapraklarındaki şekil, renk, doku üzerindeki anormalliklerini inceleyerek hastalığı bulmaya çalışmaktadır [7]. Hastalıkların en aza indirilmesi için bu hastalıkların erken dönemde tespit edilmesi ve hastalığın tedavisinden geçmektedir [8]. Bu süreçlerin teknoloji bazlı çalışmalar ile desteklenerek tarımsal faaliyetlerin etkin kullanımı hedeflenmiştir [9].

Yapay zekanın günümüzde ilerleyişi ile birlikte bu hastalık süreçlerinin yapay zeka ile tespit edilebilmesi mümkün olabilmektedir. Bilgisayarlı görme ve yapay zeka bu gibi hastalıkların tespiti için teknoloji tabanlı yöntemlerin geliştirilmesi ve hızlı, doğru otomatik sistemlerin gelişmesine olanak sağlamaktadır. Özellikle derin öğrenme algoritmaları görüntülerin analiz edilmesinde yüksek doğruluklu sonuçlar ortaya koymaktadır [10]. Yaprak hastalıklarının tespit edilmesi ve sınıflandırılması içinde yüksek doğrulukta sonuçlar üretebilmektedir. Ancak son yıllarda geliştirilen görsel dönüştürücü modeller, görüntü sınıflandırma ve nesne tespiti gibi problemlerde daha yüksek başarımlar sergilemektedir [11].

Yapay zeka sağlık, biyoloji, sanayi, savunma, eğitim, tarım gibi alanlarda yapılan çalışmalarla insanoğluna kolaylıklar sağlamaktadır [12-16]. CNN tabanlı bir anlayış olan derin öğrenme mimarilerinde AlexNet, VGGnet, ResNet, GoogleNet, SqueezeNet, Inception gibi mimari yapılar görüntü sınıflandırma ve tespit işlemlerinde kullanılmaktadır [17]. Dönüştürücü model ise Doğal Dil İşleme (DDİ) sorunlarının çözümü için ortaya konmuştur. Attention Is All You Need [18] makalesi ortaya konan bu yaklaşıma bir örnektir.

DDİ için kullanılan dönüştürücü modeller görüntü işleme içinde kullanılabilirliği amacıyla "An image is worth 16x16

words" başlıklı çalışma ile ortaya konmuştur [19]. Bu model en yaygın olarak kullanılan CNN-Evrişimli sinir ağlara karşık bir yapay zeka modelidir. Hem daha az hesaplama kaynağı kullanması hem de CNN mimarilerine göre daha başarılı sonuçlar ortaya koyması sebebiyle son birkaç yılda ön plana çıkmaktadır. DDİ'de kullanılan dikkat mekanizması görüntü işlemede de yer alması sebebiyle görüntüdeki özniteliği yüksek olan kısımlara daha çok dikkat etmektedir. Bu da görüntü sınıflandırma, nesne tespiti gibi konularda oldukça başarılı olmasına imkan sağlamaktadır. Görüntü sınıflandırma başarısı yüksek olması, bitki hastalıklarının tespitinde daha önce yapılan çalışmalarda az sayıda sınıfla çalışılmış olması, bitki hastalıklarındaki karmaşık örüntülerin dikkat mekanizmasıyla daha iyi saptayacağı düşünülmüştür. Bu da çalışmada Vit 16B modelinin tercih edilmesine etken olmuştur.

Bu çalışmada 36 sınıftan olan hasta ve sağlıklı yaprak görüntüleri kullanılarak yaprakların hangi sınıfa ait olduğunun tespit edilmesi için bir yöntem önerilmiştir. Yöntem iki aşamada gerçekleştirilmiştir. Birinci aşamada yaprak görüntülerinin arka planının yaprak görüntüsünden ayrılması için bir bölütleme yapılmıştır. RGB renk uzayından HSV renk uzayına dönüştürülen görüntü içerisinde yaprak ve arka plan ayrıştırılarak sadece yaprak görüntüsünün olduğu bir görüntü elde edilmiştir. İkinci aşamasında ise elde edilen bölütlenmiş görüntü dönüştürücü model olan ön tanımlı Vit 16B modeli kullanılarak eğitim yapılmıştır. Eğitim yapıldıktan sonra değerlendirme metrikleri kullanılarak sonuçlar elde edilmiştir. Çalışmada ortaya çıkan sonuçlar umut verici nitelikte olup daha önce yapılan çalışmalardan daha yüksek başarımlar elde etmiştir.

## 2. İlgili çalışmalar

Bitki hastalıklarının tespiti için yürütülen alan yazın araştırmaları, bu çalışmadan elde edilen sonuçların değerini ve önemini açıkça ortaya koymuştur. Mevcut kaynakların ayrıntılı bir incelemesi ve bu çalışma sırasında elde edilen sonuçlar sistematik bir biçimde verilmiştir.

Zhou ve ark. tarafından yapılan çalışmada elmadaki hastalığın teşhisi için elma yaprağı veri kümesi kullanılmıştır. Hastalığın tespiti için segmentasyon yapılmış ve 0.829 IoU benek düzeyinde başarı sağlanmıştır. Denetimli evrişimli sinir ağları ile WSLSS zayıf denetimli yaprak lekesi segmentasyon modeli önerilmiştir [20].

Pavithra ve ark. patates yapraklarındaki hastalıkları tespit edebilmek için yaptıkları çalışmada DL-APLDDC algoritması ile U2Net tabanlı arka plan kaldırma tekniği kullanmışlardır. Özellik çıkarımı için ise SqueezeNet modeli kullanılmıştır. DL-APLDDC modeli ile %96,54 doğruluk elde etmişlerdir [21].

PlantVillage veri kümesi kullanılarak 4306 görüntü örneklemeden hastalıklı ve sağlıklı bitki yaprakları kullanılan bir başka çalışmada 4 sınıftan oluşan bir sınıflandırma yapılmıştır. Evrişimli sinir ağı kullanılarak yapılan bu çalışmada %97,35 doğruluk elde edilmiştir. 32x32 benek boyutundaki görüntüler CNN temelli SVM kullanılarak sınıflandırılmıştır.

Agarwal ve ark. Plantvillage veri kümesi ve DAGS veri setinden bir arka plan sınıfını kullanarak bitki hastalıklarını teşhis edebilmek için 38 sınıflı görüntü kümesi kullanılmıştır. DenseNet169 ve AlexNet ile derin öğrenme modelleri ile tekrar eğitim yapılarak %99,72 ve %99,24 doğruluğa ulaştığı vurgulanmıştır [22]. Ancak burada elde edilen sonuçlar ikinci kez eğitime tabi tutulduğu için bu sonuçların elde edilmesi olağan olarak görülmüştür.

Bir başka çalışmada PlantVillage görüntü kümesi kullanılarak derin öğrenme modelleri ile yaprak hastalıkları sınıflandırılmıştır. 38 sınıftan oluşan görüntü kümesi DenseNet-121, ResNet-50, VGG-16 ve Inception V4 modelleri kullanılmıştır. Bu modellerden en iyi sonucu DenseNet-121 vermiş ve %99,81 başarımla elde edilmiştir [23].

Çoklu derin öğrenme modellerini kullanarak yaprak hastalıklarının sınıflandırılması için yapılan bir çalışmada TLU-yaprak veri kümesi ayrıca Manyok yaprak hastalığı veri kümesi (Cassava) kullanılmıştır. ResNet50 derin öğrenme modeli ile elde edilen başarımla %90 olarak vurgulanmıştır. EfficientNet B5, Mobilnet V3 modelleri de kullanılarak yapılan çalışmada elde edilen en iyi sonuç vurgulanmıştır [24].

LSTM, RNN ve CNN ve derin öğrenme modelleri kullanılarak yaprak hastalıklarının sınıflandırılması çalışmasında farklı modeller üzerine çalışılmış ve ortalama %96 başarımla elde edildiği vurgulanmıştır. EfficientNet, MobilNet SqueezeNet gibi modeller kullanılmıştır. Çalışmada modellerin ne kadar alan kapladığı, eğitim ve sınav süreleri ile ne kadar enerji tüketimi yaptıkları da ortaya konmuştur. MobilNet'in boyut olarak küçük olması sebebiyle akıllı tarım çalışmalarında kullanımı önerilmiştir [25].

Patates yapraklarından hastalığın tespit edilebilmesi için yapılan bir çalışmada derin öğrenme modelleri kullanılmış ve ResNet modeli ile %98,14 doğruluk elde edildiği vurgulanmıştır. PlantVillage veri kümesinde yer alan 2210 patates yaprağı görüntüsü alınmış ve bunların 1700 adet görüntü eğitim için 452 adet görüntü ise sınav için kullanılmıştır. Görüntüler eğitim için %70 sınav için %30 oranında kullanılmıştır. VGG16 modeli %96,29, InceptionV3 %97,77, MobilNetV2 %90,12, NasNetV2 %98,12, ResNet %98,14 başarımla elde etmiştir. Çalışmada ayrıca optimizasyon yöntemlerinden Adam, SDGM, RMS kullanılmış ve elde edilen sonuçlar ortaya konmuştur [26].

PlantVillage veri kümesinde yer alan domates, patates, biber bitki yapraklarına ait görüntülerden oluşan 15 sınıf içeren bir veri kümesi kullanılmış ve farklı derin öğrenme modelleri ile transfer öğrenme kullanılarak sonuçlar elde edilmiştir. InceptionV3, MobileNet, DenseNet121, Inception-ResNetV2 ve ResNet152v2 modelleri ile elde edilen sonuçlarda %99,4 başarımla DenseNet121 modeli en iyi sonucu üretmiştir. InceptionV3 83,7 MobileNet 99,4 DenseNet121 99,4 InceptionResnetV2 98,5 Resnet152V2 64,3 başarımla elde ettiği vurgulanmıştır [27].

Yapılan çalışma alan yazın araştırmalarındaki farklı yapay zeka modelleri ile karşılaştırılmıştır. Çizelge-1 de bu çalışmaların yer aldığı veri setlerine ait bilgiler yer almaktadır.

**Çizelge-1: Kaynaklarda Yer Alan Veri Kümeleri ve Özellikleri**

| Veri Kümesi                           | Yılı | Tür Sayısı | Hastalık Türü | Sınıf Sayısı | Görüntü Sayısı |
|---------------------------------------|------|------------|---------------|--------------|----------------|
| Plant Village[28]                     | 2016 | 14         | 22            | 38           | 54.303         |
| plant leaves[29]                      | 2019 | 12         | 22            | 22           | 4.503          |
| Plantae_k[30]                         | 2019 | 8          | 9             | 16           | 2.157          |
| PlantDoc[31]                          | 2020 | 13         | 17            | 28           | 2.598          |
| Plant pathology 2021 - FGVC8[32]      | 2021 | 1          | 6             | 6            | 3.651          |
| Maize leaf (NLB)[33]                  | 2018 | 1          | 2             | 2            | 18.000         |
| Citrus leaves[34]                     | 2019 | 1          | 5             | 5            | 594            |
| Rice diseases image dataset[35]       | 2019 | 1          | 4             | 4            | 5.447          |
| JMuBEN Arabica coffee leaf images[36] | 2021 | 1          | 3             | 5            | 22.591         |
| JMuBEN2[36]                           | 2021 | 1          | 2             | 5            | 58.555         |
| JMuBEN3 sweet potato leaf spot [36]   | 2021 | 1          | 1             | 1            | 2.003          |
| Cassava diseases[37]                  | 2019 | 1          | 5             | 5            | 21.397         |
| UCI rice leaf diseases [38]           | 2017 | 1          | 3             | 3            | 120            |

Çizelge-1'de kaynaklarda sıklıkla kullanılan veri kümeleri ve bu veri kümelerinin ayrıntıları yer almaktadır. Veri kümeleri içerisinde en çok sınıfa sahip olan çalışmamızda da kullanılan plantVillage veri kümesidir. Hem tür sayısı hem hastalık türü olarak çoklu sınıflandırma ve modellerin sınavması için önemli bir veri kümesidir. Ayrıca bu veri kümesi en fazla görüntü sayısına sahiptir. Diğer veri kümelerinde tür sayısı hastalık türü sınıf sayısı ve görüntü sayısı olarak çeşitliliği düşüktür. Çalışmamızda sınıf ve örneklem sayısı yüksek miktarda olan Plant Village veri kümesi tercih edilmiştir. Kaynak araştırmalarında yapılan bazı çalışmalar için Plant Village veri kümesindeki az sayıda sınıflar tercih edilmiş olup farklı sonuçlar ortaya konduğu görülmektedir.

Dönüştürücü modeller, derin öğrenme modellerinden sonra ortaya çıkmış bir yapay zeka modelidir. Özellikle görüntü işleme alanında örneklem sayısının yüksek olduğu çalışmalarda başarımla oranın oldukça iyi olduğu bilinmektedir. Bitki yapraklarından hastalık tespit edilmesine yönelik yapılan dönüştürücü modelleri yaklaşımlar oldukça kısıtlıdır. Bu çalışmalar az ve sınırlı sayıda olduğu görülmüştür. Bu çalışmalardan birinde PlantVillage, PlantDoc, Cd&S veri kümelerindeki mısır yapraklarına ait görüntü kümeleri birleştirilerek bir görüntü kümesi elde edilmiştir. Bu veri kümesinden mısırdaki hastalıkların tespitinin dönüştürücü modellerden MaxVit modeli ile yapılan çalışmada %94,24 başarımla elde edilmiştir [39]. Bir başka çalışmada swin dönüştürücü model kullanılmış ve patates yapraklarındaki hastalıklar tespit edilmeye çalışılmıştır. Bu modelle %97,7 başarımla elde edilmiştir [40]. Bir başka çalışmada göresel dönüştürücü model kullanılarak erik yapraklarındaki hastalıklar sınıflandırılmıştır. 6 sınıflı kullanılan veri kümesinde elde edilen başarımla %97,51 olarak verilmiştir [41]. Bir başka çalışmada PlantVillage veri setindeki 14 tür içeren bitkilerden 24 tür hastalıklı yaprak

sınıflandırılması yapılmıştır. Çalışmada CNN modeli bir dönüştürücü model kullanılmış ve %99.62 başarımla elde edilmiştir [42]. Bir başka çalışmada, MaxVit kullanılarak domates yaprağı hastalıklarını sınıflandırmada genel bir doğruluk elde ettiğini, EAnet ile %89, CCT ile % 91 PVT modeli ile %93 başarımla elde ettiği vurgulanmıştır [43]. Yapılan kaynak taramalarında görsel dönüştürücü modeller ile yapılan çalışmaların sınırlı kaldığı bu noktada bir açık olduğu

görülmüştür. Bitki hastalıklarının tespiti ile ilgili son yıllarda çalışmalar artmaktadır. Bu çalışmalarda dönüştürücü modellerinin başarımlı sonuçlar elde etmektedir [44-46]. Çeşitli veri kümelerinde bu modellerle elde edilen sonuçlar %98-%99 gibi etkiler göstermektedir [45, 47]. Ayrıca yapılan kaynak taramalarında bazı çalışmalar bir araya getirilerek çizelge 2’de verilen karşılaştırmalı kaynak incelemeleri ortaya konmuştur.

**Çizelge-2: Dönüştürücü Modeller ile Yapılan Çalışmaların Karşılaştırılması**

| Çalışma                       | Sınıflandırma Doğruluğu                         | Hesaplamalı Verimlilik                           | Model Sağlamlığı                                  | Ölçeklenebilirlik ve Genellenebilirlik                 |
|-------------------------------|-------------------------------------------------|--------------------------------------------------|---------------------------------------------------|--------------------------------------------------------|
| (Nandana et al., 2025)        | Topluluk swin dönüştürücü %98.92                | Yüksek hesaplama ihtiyacı                        | Ensemble, tek modellere göre daha sağlam          | PlantVillage üzerinde, çok tür uygulanabilirliği       |
| (Ding et al., 2024)           | ViT modelleri %99,7                             | Bazı ViT'ler hesaplama maliyeti yüksek.          | Gerçek dünya dağıtımındaki zorlukları tartışır    | Veri kümeleri ve mahsuller arasında kapsamlı taksonomi |
| (Akter et al., 2024)          | Optimize edilmiş CCT modeli %98.87              | Verimlilik için optimize edilmiş CCT modeli      | Domates yaprağı görüntülerinde sağlam             | Çeşitli tarımsal ortamlara ölçeklenebilir              |
| (Mustofa et al., 2023)        | ViT ve CNN modelleri yüksek doğruluk ~% 95-99   | CNN hızlı, dönüştürücü daha yavaş                | Sağlamlık, büyüme ve veri kümesine bağlıdır       | Çoklu veri kümeleri, geniş uygulanabilirlik            |
| (Dubey et al., 2025)          | Hafif CNN'ler ve ViT topluluğu %97.85           | Raspberry Pi'de düşük çıkarım süresi (20,5 ms)   | Veri artırma ile yüksek sağlamlık                 | Gerçek zamanlı kullanım                                |
| (Abdullah et al., 2024)       | CompactVit varyantı% 97                         | MobileVit daha az verimli                        | ViT varyantları domates hastalığında iyi          | Çok kaynaklı domates veri kümeleri kullanıldı          |
| (Mallick et al., 2025)        | HvT dönüştürücü %99.3                           | MobileNetv3 daha az verimli                      | Dönüştürücü modeller daha iyi başarımla           | Birden fazla ürün içeren geniş araştırma               |
| (Henry et al., 2025)          | ViT, ~% 99, EfficientNet ve ResNet'ten daha iyi | CNN'ler hızlı, ViT daha fazla kaynak gerektirir  | Veri artırma ile geliştirilmiş sağlamlık          | Büyük artırılmış veri kümesi kullanıldı                |
| (Bheemalli et al., 2025)      | Swin Dönüştürücü %97.4 doğruluk, ViT% 96.8      | Dönüştürücü model CNN'lerden daha yavaş          | Yorumlanabilir ve daha sağlam                     | Büyük elma yaprağı veri kümeleri                       |
| (Goli & Abraham, 2025)        | Swin Dönüştürücü modeli% 99.39                  | Tahmin hızı 13s, verimli                         | Bulanık optimizasyon ile daha iyi sağlamlık       | PlantVillage veri kümesi                               |
| (Baek, 2025)                  | Multi-ViT %99                                   | Hesaplama açısından zorlu                        | Elma, üzüm, domates verilerinde sağlam            | Çoklu mahsul veri kümeleri                             |
| (Liu et al., 2025)            | ConvTransNet-S hibrit modeli %98,85             | 7,56 ms çıkarım süresi, orta karmaşıklık         | Karmaşık ortamlarda sağlam                        | PlantVillage ve saha içi veri kümeleri                 |
| (Sharma et al., 2025)         | Hibrit CNN-ViT modeli% 97.38                    | Azaltılmış eğitim hataları ve hesaplama yükü     | Gerçek tarımsal kullanım için sağlam ve güvenilir | PlantVillage veri kümesi                               |
| (Aswani & Sinha, 2025)        | Hibrit CNN-ViT modeli% 97.43                    | Şeker kamışı hastalıkları için verimli           | Sınıflar arasında sağlam genelleme                | Şeker kamışı yaprağı veri kümesi                       |
| (Fahim-UI-Islam et al., 2024) | Dönüştürücü ile federe öğrenme %99              | Hafif budanmış modeller çıkarım süresini azaltır | Düşük kaynaklı federe ayarlarda sağlam            | Buğday yaprağı hastalığı veri kümesi                   |
| (Aboelenin et al., 2025)      | Hibrit CNN-ViT modeli% 99.24                    | Hesaplama verimliliği geliştirir                 | Elma ve mısır veri kümeleri için sağlam           | Elma ve mısır veri kümeleri                            |


Yapılan kaynak çalışmalarında görsel dönüştürücü modelleri oldukça başarılı sonuçlar elde etmesi sebebiyle çalışmada kullanılan model seçiminde etkili olmuştur.

### 3. Yöntem

Bu çalışmada, bitki yapraklarındaki hastalıkları tespit etmek için 8 derin öğrenme modeli ve dönüştürücü model kullanıldı. Veri kümesindeki görüntülerin yetersiz olması nedeniyle, veri artırma yapıldı ve görüntüdeki yaprakları vurgulamak için bölütleme yapıldı. Sonuçları değerlendirmek için değerlendirme metrikleri hakkında bilgi sağlandı. Uygulama süreci hakkında bilgi sağlandı.

### 3.1 Veri Kümesi

Çalışmada PlantVillage [48] veri kümesi kullanılmıştır. Bu veri kümesinde yer alan ve 36 sınıftan oluşan sağlıklı ve sağlıklı bitki yapraklarına ait görüntüler yer almaktadır. Elma, yaban mersini, vişne, mısır, üzüm, portakal, şeftali, biber, patates, ahududu, soya fasulyesi, kabak, çilek, domates bitkilerine ait sağlıklı ve hastalıklı yaprak görüntüleri bulunmaktadır. Bu bitkiler 14 farklı tarım ürününe ait yaprakları içermektedir. Veri setindeki her bir sınıfa ait yaprak görüntüleri şekil-1’de verilmiştir. Numaralandırılmış olarak verilen bu görüntülerde yaprak numarası ile birlikte sağlıklı veya hastalıklı sınıf bilgisi de yer almaktadır.



**Şekil-1:** Sağlıklı ve Sağsız yaprak görüntüleri (1.Elma Kabuklu Biti, 2.Elma Kara Çürüklüğü, 3.Elma Sedir Elma Pası, 4.Elma Sağlıklı, 5.Yaban Mersini Sağlıklı, 6.Kiraz Sağlıklı, 7.Kiraz Külleme, 8.Mısır Gri Yaprak Lekesi, 9. Mısır Yaygın Pas, 10.Mısır Sağlıklı, 11.Mısır Kuzey Yaprak Yanıklığı, 12.Üzüm Kara Çürüklüğü, 13.Üzüm Kara Kızamık, 14.Üzüm Sağlıklı, 15.Üzüm Yaprak Yanıklığı, 16.Portakal Turuncgil Yeşillenmesi, 17.Şeftali Bakteriyel Leke, 18.Şeftali Sağlıklı, 19.Biber Bakteriyel Leke, 20.Biber Sağlıklı, 21.Patates Erken Yanıklık, 22.Patates Sağlıklı, 23.Patates Geç Yanıklık, 24.Ahududu Sağlıklı, 25.Soya Fasulyesi Sağlıklı, 26.Kabak Küllemesi, 27.Çilek Sağlıklı, 28. Çilek Yaprak Yanıklığı, 29.Domates Bakteriyel Leke, 30.Domates Erken Yanıklık, 31.Domates Sağlıklı, 32.Domates Geç Yanıklık, 33.Domates Yaprak Küfü, 34.Domates Yaprak Lekesi, 35.Domates Mozaik Virüsü, 36.Domates Sarı Yaprak Kıvrılma Virüsü)

Veri kümesinde yer alan görüntü örneklem sayısı yaklaşık 53 bindir. Bu kaynaklarda kullanılan en geniş sınıfa ve görüntüye sahip veri setlerindendir.

### 3.2 Ön İşleme

PlantVillage veri kümesi içerisinde bazı sınıflarda örneklem sayısında düzensizlik yer almaktadır. Bu düzensizliğin giderilmesi için veri artırma yöntemleri uygulanmıştır.

#### 3.2.1 Veri Artırma

Veri kümesinde yer alan sınıflarda örneklem sayısı düzensiz olduğundan bazı sınıflardaki görüntüler veri çoğaltma yöntemleri kullanılarak görüntü sayıları artırılmıştır. Veri artırılması modelin sınıflar arası dengesizliğinden dolayı öğrenmede yanlı davranması önlenmiştir. Döndürme (90,180), yansıma, tersleme gibi veri artırma işlemleri uygulanarak görüntü miktarı artırılmıştır. Bu artış görüntü çeşitliliğini artırmış modelin genelleme yeteneğini artırmıştır. Veri artırımı aynı zamanda modelin sınırlı örnekler yerine eşit şekilde dağıtılmış örneklem sayılarının aşırı öğrenme yapmasının önüne geçmektedir. Çalışmada kullanılan veri kümesinde yalnızca eğitim örnekleri veri artırma yöntemleri kullanılarak çoğaltılmıştır. Test kümesinin her sınıfında

karşılaştırılabilir sayıda örneklem olması için %80 eğitim %20 sinama oranı korunmaya çalışılmıştır. Her sınıftaki örneklem sayıları dengeli şekilde dağıtılmıştır. Böylece modelin düşük örnek sayısına ait sınıflarda da başarılı sonuçlar üretmesi sağlanmıştır. Veri artırımı öncesinde yapılan eğitim ve sinama sürecinde düşük örneklem sayısının yer aldığı sınıfların daha düşük başarımla gösterdiği veri artırımı sonrası daha yüksek başarımla elde ettiğini göstermiştir. Görüntülerin yer aldığı sınıflar ile eğitim veri artırma sonrası ve sinama için kullanılan görüntü sayıları Çizelge-3'de verilmiştir. Veri kümesinde yer alan her bir görüntünün 256x256 boyutlarında yer almaktadır. 14 tür, 22 hastalık ve toplam 36 sınıfın yer aldığı veri kümesi kullanılmıştır. 36 sınıftan oluşan veri kümesi ve bu veri setlerinde yer alan örneklem sayıları çizelgede belirtilmiştir.

**Çizelge-3: Veri Kümesinde Kullanılan Sınıflar ile Eğitim Sinama için Kullanılan Örnek Sayıları**

| SN | Bitki Yaprak Hastalık Sınıfı | Eğitim Örnek Sayısı | Sinama Örnek Sayısı |
|----|------------------------------|---------------------|---------------------|
| 1  | Elma Kabuklu Biti            | 2008                | 502                 |
| 2  | Elma Kara Çürüklüğü          | 1988                | 497                 |
| 3  | Elma Sedir Elma Pası         | 1512                | 378                 |

|    |                                       |      |     |
|----|---------------------------------------|------|-----|
| 4  | Elma Sağlıklı                         | 2008 | 502 |
| 5  | Yaban Mersini Sağlıklı                | 1800 | 450 |
| 6  | Kiraz Sağlıklı                        | 1824 | 456 |
| 7  | Kiraz Külleme                         | 1556 | 389 |
| 8  | Mısır Gri Yaprak Lekesi               | 1612 | 403 |
| 9  | Mısır Yaygın Pas                      | 1864 | 466 |
| 10 | Mısır Sağlıklı                        | 1856 | 464 |
| 11 | Mısır Kuzey Yaprak Yanıklığı          | 1844 | 461 |
| 12 | Üzüm Kara Çürüklüğü                   | 1888 | 472 |
| 13 | Üzüm Kara Kızamık                     | 1920 | 480 |
| 14 | Üzüm Sağlıklı                         | 1692 | 423 |
| 15 | Üzüm Yaprak Yanıklığı                 | 1712 | 428 |
| 16 | Portakal Turuncgil Yeşillenmesi       | 1960 | 490 |
| 17 | Şeftali Bakteriyel Leke               | 1676 | 419 |
| 18 | Şeftali Sağlıklı                      | 1724 | 431 |
| 19 | Dolmalık Biber Bakteriyel Leke        | 1904 | 476 |
| 20 | Dolmalık Biber Sağlıklı               | 1956 | 489 |
| 21 | Patates Erken Yanıklık                | 1900 | 475 |
| 22 | Patates Sağlıklı                      | 1696 | 424 |
| 23 | Patates Geç Yanıklık                  | 1912 | 478 |
| 24 | Ahududu Sağlıklı                      | 1780 | 445 |
| 25 | Soya Fasulyesi Sağlıklı               | 2020 | 505 |
| 26 | Kabak Küllemesi                       | 1736 | 434 |
| 27 | Çilek Sağlıklı                        | 1824 | 456 |
| 28 | Çilek Yaprak Yanıklığı                | 1688 | 422 |
| 29 | Domates Bakteriyel Leke               | 1692 | 423 |
| 30 | Domates Erken Yanıklık                | 1876 | 469 |
| 31 | Domates Sağlıklı                      | 1848 | 462 |
| 32 | Domates Geç Yanıklık                  | 1812 | 453 |
| 33 | Domates Yaprak Küfü                   | 1880 | 470 |
| 34 | Domates Septoria Yaprak Lekesi        | 1732 | 433 |
| 35 | Domates Mozaik Virüsü                 | 1788 | 447 |
| 36 | Domates (Sarı Yaprak Kıvrılma Virüsü) | 1960 | 490 |

### 3.2.2 Bitki Yapraklarının Bölütlenmesi


Yaprak görüntüsünün arka plandan ayrılması, çalışmanın başarısı açısından önemlidir. Bu sebeple yaprak görüntüsü arka plan görüntüsünden ayrıştırılmalıdır. Görüntü segmentasyonu için renk uzayının değiştirilmesi, yaprak görüntüsünün ortaya çıkarılması ve arka planın ortadan kaldırılmasını sağlayacaktır. Veri kümesinde yer alan yaprak görüntüleri RGB renk uzayına sahip kırmızı yeşil ve mavi renklerin birleşimi ile oluşmaktadır. Yaprak görüntüsünün arka plandan görüntüsünden ayrıştırılması için renk, doygunluk ve parlaklığın yer aldığı HSV renk uzayına dönüştürülmelidir. RGB renk uzayındaki görüntüler, segmentasyon için HSV renk uzayına dönüştürülmüştür. Bu dönüşüm, renk, doygunluk ve parlaklık bileşenleri esas alınarak yapılmaktadır. HSV renk temelli arka plan çıkarma işlemi literatürde sıklıkla kullanıldığından, bu çalışmada yaprak görüntüsünün arka plandan çıkarımı doğru bir tercih olarak görülmektedir. RGB renk uzayından HSV renk uzayına dönüşüm formülü aşağıdaki denklem 1,2,3'te verilmiştir.

$$H = \arctan \left( \frac{\sqrt{3}(G - B)}{(R - G) + (R - B)} \right) \quad (1)$$

$$S = 1 - \frac{\min(R, G, B)}{R + G + B} \quad (2)$$

$$V = \max(R, G, B) \quad (3)$$


Şekil-2'de RGB ve HSV renk uzayına ait görsel temsiller verilmiştir.



Şekil-2: RGB renk uzayı ve HSV renk uzayı


Bitkinin yaprak görüntüsünün yer aldığı görüntü RGB renk uzayından HSV renk uzayına dönüştürülmüştür. İşlemden sonra oluşan parlak bölge yaprak görüntüsünün bulunduğu bölge olarak tanımlanmıştır. Bölütleme ile görüntü yaprak ve arka plan olarak 2 bölüme ayrılmıştır.

Asıl yaprak görüntüsünden yaprağın elde edilmesi otomatik olarak bu yapıya göre gerçekleşmiştir. Öncelikle RGB renk uzayına sahip girdi görüntüsü HSV renk uzayına çevrilmiştir. Daha sonra H, S ve V değerleri alınarak her bir renk uzayı için dönüştürme yapılmıştır. Renk uzayının oluşturduğu yaprak görüntüsüne ait bölge ve arka plan bölgesi siyah beyaz olarak iki bölgeye ayrılmıştır. Bölgenin belirlenmesi sonrası yaprağın olduğu bölüm alınmıştır. Bu işlemin her bir adımına ait işlemlere ait akış şeması Şekil-3'te gösterilmiştir.



Şekil-3: Görüntü segmentasyonu akış şeması

Asıl görüntü a, maske bölgesi b ve arka planı çıkarılmış yaprak görüntüsü c Şekil-4'te yer almaktadır.



**Şekil-4:** Segmentasyonu yapılan yaprak görüntüsü a) orijinal görüntü b) Arka plan ve yaprak görüntüsü segmente edilmiş görüntü c) Segmentasyon sonrası kullanılacak olan yaprak görüntüsü

Veri kümesinde yer alan görüntülerin farklı ortam aydınlatmaları olması, bazı görüntülerde renk segmentasyonu yapılması sonrasında yaprak görüntüsü elde edilemeyen görüntüler veri setinden çıkarılmıştır. Çıkarılan görüntü miktarı sayısı oldukça düşük olup veri kümesinde önemsenmeyecek kadar azdır.

### 3.3 Derin Öğrenme Modelleri

Çalışmada Vit 16B modeli ile derin öğrenme model başarımlarını karşılaştırmak için bazı derin öğrenme modelleri kullanılmıştır. Aynı veri kümesi ile derin öğrenme model başarımları ortaya konmuştur. Çalışmada kullanılan derin öğrenme modelleri ise AlexNet[49], Vgg16[50], Vgg19[50], SqueezeNet[51], Resnet18-50-101 [52], GoogleNet[53]'tir.

AlexNet 2012 yılında yapılan imagenet yarışmasında birinci olan derin öğrenme modelidir. 8 derinliğe ve 25 katmana sahiptir. Dropout katmanı ilk kez kullanılan bu model aşırı öğrenmeyi azaltmak için kullanılmıştır. Görüntü sınıflandırma, nesne tespiti gibi çalışmalarda kullanılmıştır.

Vgg16 ve Vgg19 modelleri 2014 yılında geliştirilmiştir. 16 ve 19 derinliğe sahiptir. 41 ve 47 katmandan oluşmaktadır. Özniteliklerin daha iyi öğrenilmesini hedefleyen bir modeldir. Hala pek çok çalışmada kullanılmakta ve oldukça iyi başarımlar elde edilmektedir.

GoogNet ise 2014 yılında hazırlanmış, 22 katman derinliğine sahip ve 144 katmandan oluşmaktadır. Başlangıç modülleri kullanılarak farklı konvolüsyon kullanılarak çok ölçekli özellik çıkarmayı sağlamaktadır. Daha düşük donanıma sahip sistemde kullanılarak daha iyi sınıflandırma ve tespit çalışmalarında kullanılabilmektedir.

ResNet18-50-101 modelleri 2015 yılında geliştirilen ve 2016 yılında yayınlanan bir modellerdir. Atlamalı bağlandılar (Residual connection) adı verilen yapıyla öne çıkmaktadır. Yüksek derinliğe sahip modellerde meydana gelen öğrenme sorununu ortadan kaldırmak için kullanılmaktadır. 18, 50 ve 101 katman derinliğine sahip modelleri aynı yayında ortaya konmuştur. Sırasıyla toplam 70, 176, 346 katmandan oluşmaktadır [54].

SqueezeNet 2014 yılında geliştirilmiş bir modeldir. Parametre sayısının daha az olması gereken çalışmalarda daha çok tercih edilmektedir. Bu modelin temel özelliği fire modülünün olmasıdır. Fire modülünde 1x1 konvolüsyonu kullanarak veri temsili sıkıştırırken genişletmek için ise 3x3 konvolüsyon kullanır. Bu model 68 katman ve 75 bağlantıdan oluşmaktadır.

Çalışmada kullanılan derin öğrenme modelleri literatürde sıklıkla rastlanan modellerdir. Her biri farklı mimari yapılar sahip modellerdir. Her bir model farklı derinlik ve parametre sayılarına sahiptir. Çalışmada bu gibi farklı modellerin kullanılması çeşitlilik açısından önemli bir değerdir. AlexNet ve VGGNet modelleri literatürde ilk kullanılan derin öğrenme modelleridir, görüntü sınıflandırmada başarılı olarak görülmektedir. ResNet modelleri atlamalı artık bağlantıları olan derin ağ yapısına sahiptir. Farklı derinlikte modelleri vardır ve atlamalı ağlar bu modeller ile başlamıştır. SqueezeNet daha düşük parametreye sahip olması sebebiyle seçilmiştir. Düşük parametrelerde nasıl bir başarımlar elde edilebileceğini göstermek adına tercih edilmiştir. GoogleNet sahip olduğu başlangıç modülü ile farklı ölçeklendirme özelliğine sahip olduğu için tercih edilmiştir. Her biri farklı bir mimari yapıya sahip olan bu derin öğrenme modellerinin karmaşıklık düzeyleri de farklıdır. Bu karmaşıklık düzeylerinin bitki hastalıklarının tespiti üzerindeki etkisini kapsamlı şekilde değerlendirmeye olanak sağlamaktadır.

### 3.4 Değerlendirme Ölçüleri

Değerlendirme ölçüsü olarak doğruluk (accuracy) ve karmaşıklık matrisi (confusion matrix) kullanılmıştır. Doğruluk modelin tüm sınıfları doğru şekilde tahmin etme başarısını ortaya koymaktadır. Karmaşıklık matrisi ile birlikte Tuturma (Precision), Bulma (Recall) ve F1-Değeri (F1-Score) sonuçları elde edilir. Formül-4'de yer alan doğruluk değeri 0 ile 1 arasındadır. Yüzdelik olarak gösterilir. Modelin sınama verisi üzerindeki başarı oranını göstermektedir.

$$\text{Doğruluk} = \frac{\text{Doğru tahmin sayısı}}{\text{Toplam tahmin sayısı}} \quad (4)$$

Karmaşıklık matrisi ise her bir sınıfın doğru yanlış tahminlerini gösterir bir tablodur. Bu tablo sınıfların her biri için kendi ve diğer sınıflardan kaç adet tahmin edildiğini göstermektedir. Çizelgede yer alan veriler 4 kısımdan oluşur. Doğru Pozitif (True Positive-TP) doğru sınıflandırılan pozitif örnekler, Doğru Negatif (True Negative-TN) doğru sınıflandırılan negatif örnekler, Yanlış Pozitif yanlış sınıflandırılan negatif örnekler ve Yanlış Negatif yanlış sınıflandırılan pozitif örneklerdir. Buna göre Tuturma, Bulma ve F1-Değeri değerlendirme metrikleri hesaplanır. Formül 5,6,7'te bu değerlendirme metriklerinin nasıl hesaplandığı yer almaktadır.

$$\text{Tuturma} = \frac{TP}{TP + FP} \quad (5)$$

$$\text{Bulma} = \frac{TP}{TP + FN} \quad (6)$$

$$\text{F1 Değeri} = 2x \frac{\text{Tuturma} \times \text{Bulma}}{\text{Tuturma} + \text{Bulma}} \quad (7)$$

### 3.5 Görsel Dönüştürücü (Vit 16B) Model

Görsel dönüştürücü model özellikle doğal dil işleme alanında (DDİ) ve görüntü işleme alanında ön plana çıkmaktadır. Görüntü işleme alanında veri miktarı arttıkça derin öğrenme modellerinden daha başarılı sonuçlar göstermektedir. Görsel Dönüştürücü modellerin temelinde “self-attention” yani dikkat mekanizması modelin önemli bir yapısıdır. Bu mekanizma giriş verisinin diğer verilerle olan ilişkisini ve önemini ortaya koymaktadır. Modele giren her elaman (görüntü) kendinden önce gelen görüntü ile etkileşim içerisinde. Dikkat mekanizması girdi görüntüsünün her biri için 3 farklı vektör oluşturur. Sorgu (Query), anahtar (Key), değer (Value). Sorgu vektörü her bir görüntünün kendinden önce ağırlıklı olarak gelen görüntü ile olan ilişkisi hakkında bilgi içerir. Anahtar ise girdi görüntüsünün kendisine ait ayrıntıları barındırır. Değer vektörü ise görüntünün taşıdığı asıl özellikler temsil eder.

Görsel dönüştürücü modele ait özellikler Çizelge-4’te verilmiştir.

**Çizelge-4. Vit 16B Model Mimari Özellikleri**

| Özellik               | Değer   |
|-----------------------|---------|
| Patch size            | 16×16   |
| Giriş boyutu          | 224×224 |
| Encoder blok sayısı   | 24      |
| Toplam katman         | 384     |
| Gizli boyut           | 1024    |
| MLP genişleme faktörü | 4       |
| Başlık                | 16      |
| Toplam parametre      | 86 M    |

Vit 16B modelinde görüntüler 16×16 boyutunda parçalara ayrılmaktadır, görüntü girdi boyutu 224×224 olup, toplamda 24 kodlayıcı bloktan oluşmakta ve 384 katmandan oluşmaktadır. Modelin gizli katman boyutu 1024, MLP genişleme oranı 4, çoklu başlık sayısı 16’dır. Toplamda 86 milyon parametre içermektedir.

Model içerisinde her bir görüntü yaması, diğer yamalarla olan ilişkisini sorgu ve anahtar vektörleri arasındaki dikkat mekanizması aracılığı ile öğrenir. Bu durum görüntüdeki anlamlı bölgeleri öne çıkarır. Böylelikle sınıflandırma sürecine katkı sağlamış olur. Bu bağ belirli ölçeklendirmeler ve softmax fonksiyonu ile ağırlıklarını hesaplar. Ağırlıklar görüntünün kendi değer vektörü ile çarpılır ve dizinin her görüntüsüne uygun şekilde bir çıkış verisi üretir. Böylece görüntü diğer görüntülerle olan bağı öğrenir ve verilerin tüm özelliklerini dikkate alır.

Ayrıca görüntüler küçük parçalara ayrılır. Her parça için belirli bir pozisyon kodlaması yapılır. Her giriş görüntüsüne ait bir pozisyon vektörü üretilir. Bu da ilişkilerin öğrenilmesinde önemli bir noktadır.


Dönüştürücü modelin diğer bir özelliği ise Çok Başlı Dikkat Mekanizmasıdır (Multi-Head Self Attention). Aynı anda birden fazla bakış açısıyla çalışarak daha fazla ilişkilerin öğrenilmesini sağlamaktadır. Ardaşık şekilde çok başlı dikkat mekanizmaları birbirine tamamen bağı katmanlardan oluşmaktadır. Çıktı katmanında sınıflandırma ve tahminin yapılabilmesi için bir softmax fonksiyonu kullanılmaktadır.

Vit 16B modelinde görüntüler 16×16 benek boyutunda parçalara ayrılır. Her parça modelin anlayabileceği bir vektöre dönüştürülür. Her bir vektörün sıra bilgisi modele öğretilir. Model her parçanın görüntüdeki yerini öğrenir. Dikkat mekanizması her parçanın ağırlıklarını öğrenir ve birbirleri ile arasındaki ağırlıkları değerlendirir. Her dikkat mekanizmasında normalizasyon ve geri besleme ile desteklenir. Bu yapı modeldeki karmaşıklığı daha iyi öğrenmesini sağlar. Son katman sınıflandırma katmanı olarak yer alır ve görüntünün sınıflandırılmasını sağlar.

Bu çalışmada Vit 16B modelinin tercih edilme sebepleri şu şekilde sıralanabilir;

- CNN modellerinin aksine görüntüyü global olarak işler. Bu da yaprağın bir bütün olarak değerlendirilerek hastalık etmenlerinin ortaya çıkarılmasını sağlar.
- Yapılan literatür taramaları Vit 16B, CNN modellerine göre daha etkili sonuçlar üretmektedir.
- Yüksek parametre içerdiği için yapraktaki küçük değişiklikleri de fark edebilecek bir yapıya sahiptir.
- Yaprak hastalıklarının bazıları bölgesel ve düzensizdir. Vit 16B modelinin yama tabanlı yapısı bölgesel örüntüleri etkili şekilde tespit edebilme yeteneğine sahiptir.
- Büyük veri setleri üzerinde göstermiş olduğu yüksek başarımla çalışmada kullanılan veri kümesinde yaklaşık 53 bin görüntü yer alması.
- Vit 16B büyük görüntü veri setleri ile önceden eğitildiği için transfer öğrenmeyle yeni çalışmalarda etkili sonuçlar sunar.

Yaprak hastalıklarının Vit-16B modeli ile sınıflandırması işlemi şekil-5 ile gösterilmiştir.




**Şekil-5: Çalışmada kullanılan Vit 16B Dönüştürücü Model yapısı**

Çalışmada kullanılan ViT 16B modeline ait mimari şekil-5’te yer almaktadır. Giriş bitki yaprağı görüntülerini 16×16 boyutunda yamalara ayırarak işlemektedir. Görüntüden elde edilen yamalar, modelin kodlayıcı bloklarına aktarılmakta ve bu bloklarda çok başlıklı dikkat mekanizması ile hastalığa özgü özellikler çıkarılmaktadır. Elde edilen bu özellikler, sınıflandırıcı katman aracılığıyla ilgili hastalık sınıfına atanmakta ve sonuç olarak yaprak üzerindeki hastalığın türü

tespit edilmektedir. Bu şekil modelin bitki yaprağı görüntüsü üzerindeki analiz sürecini adım adım göstermektedir.

Yapılan bu çalışmada Vit 16B modeli ve diğer derin öğrenme modelleri ile bitki hastalıklarının tespit edilmiştir. Elde edilen

başarımları karşılaştırmak için tüm modeller eğitim ve sınama sürecinden geçmiştir. Önerilen modelin diyagramı şekil-6'da yer almaktadır.



Şekil-6: Önerilen modele ait grafik gösterim

Çalışmada kullanılan her bir derin öğrenme modeli ve Vit 16B modeli için 5-fold çapraz doğrulama kullanılmıştır. Modellerin performansını genelleme yapması ve aşırı öğrenmeyi en aza indirmek için bu yöntem kullanılmıştır. Bu kapsamda her bir model için eğitim ve sınama veri kümesi rasgele olarak alınmıştır. Bu modellerin veri kombinasyonlardaki başarımını ölçmek için yapılmıştır. Veri setinin bu şekilde kullanılması modellerin aynı veri setlerinde farklı 5-fold çapraz doğrulama ile genelleme ve güvenilirliğini artırmaktır. Ayrıca veri kümesi eğitim için %80 sınama için %20 olmak üzere ayrılmıştır. Derin öğrenme modelleri için çizelge-5'te yer alan hiperparametreler tüm modeller için kullanılmıştır.

Çizelge-5. Derin Öğrenme Modelleri için Kullanılan Hiperparametreler

| Hiperparametreler        | Değer     |
|--------------------------|-----------|
| Maksimum Epoch           | 40        |
| Öğrenme oranı            | 0,0001    |
| Batch boyutu             | 32        |
| Optimizasyon Algoritması | SGDM      |
| Momentum                 | 0,9       |
| LearnRateDropFactor      | 0,1       |
| LearnRateDropPeriod      | 10        |
| Shuffle                  | Her Epoch |
| L2Regularization         | 0,0001    |
| VerboseFrequency         | 50        |
| ValidationFrequency      | 10        |

Vit 16B modeli için kullanılan hiperparametreler ise çizelge-6'te verilmektedir. Her iki model için benzer özelliklere sahip hiperparametreler kullanılmaya özen gösterilmiştir.

Çizelge-6: Vit 16B Modeli için Hiperparametreler

| Hiperparametreler | Değer |
|-------------------|-------|
| Maksimum Epoch    | 40    |

|                          |           |
|--------------------------|-----------|
| Öğrenme oranı            | 0,001     |
| Batch boyutu             | 32        |
| Optimizasyon Algoritması | Adam      |
| Momentum                 | 0,9       |
| LearnRateDropFactor      | 0,1       |
| Shuffle                  | Her Epoch |
| L2Regularization         | 0,0001    |

#### 4. Sonuçlar

Önerilen yöntemde bitki yapraklarından arka plan çıkarımı yapılmış ve elde edilen net yaprak görüntüsü görsel dönüştürücü model olan Vit 16B modeli ile eğitilmiştir. Aynı şekilde 8 farklı derin öğrenme modellerinde bitki yapraklarındaki hastalıkların tespiti üzerine uygulaması yapılmıştır. Derin öğrenme modellerinden elde edilen sonuçlar ve Vit 16B modeli ile elde edilen sonuçlara ait bilgiler Çizelge-7'da yer almaktadır.

Çizelge-7. Vit 16B Modeli ve 8 Farklı Derin Öğrenme Model Sonuçları

| Model      | Başarım(Accuracy) |
|------------|-------------------|
| AlexNet    | 96,68             |
| SqueezeNet | 89,46             |
| ResNet18   | 98,20             |
| ResNet50   | 97,98             |
| ResNet101  | 98,32             |
| GoogleNet  | 96,60             |
| Vgg16      | 98,57             |
| Vgg19      | 98,30             |
| Vit 16B    | 99,87             |

Çalışmada yer alan derin öğrenme modelleri ve önerilen Vit 16B Görsel Dönüştürücü Model başarımlarına ait karşılaştırma verilmiştir. Derin öğrenme modellerinden en düşük başarımlar SqueezeNet olurken en yüksek başarımlar

%98,57 ile Vgg16 modeli olduğu görülmektedir. Önerilen modelin başarımları ise %99,87 olduğu ve çalışmada kullanılan tüm modellerden daha iyi sonuç ortaya çıktığı görülmüştür.

Çalışmada önerilen model ile elde edilen sonuçlar daha detaylı incelenmek istediğinde ise çizelge-6'da önemli göstergeler ile verilmiştir. Çizelge-7'de tespit edilen 36 sınıf yaprak görüntüsüne ait karmaşıklık matrisini sunmaktadır. Bu matriste sıcaklık haritası ile birlikte doğru, yanlış tespit edilen tüm sınıflara ait değerler ortaya konmuştur.

Ayrıca önerilen yöntemde her bir sınıf elde edilen kesinlik, duyarlılık, f1 değerleri Çizelge-8'de gösterilmektedir. Çizelge-8'ye yer alan verilere göre en iyi tahmin edilen sonuçlar sağlıklı mısır yaprakları ve sağlıklı üzüm yaprakları olduğu görülmektedir. Burada elde edilen sonuçların %100 şeklinde olması en iyi skorun elde edildiğini göstermektedir. Kesinlik oranı %100,00 ile en yüksek özelliklerine sahip sınıflar sedir elması pası, kiraz sağlıklı, mısır sağlıklı, üzüm sağlıklı, ahududu sağlıklı, çilek yaprağı yanığı olmuştur. Duyarlılık oranı %100,00 ile en yüksek özelliklere sahip sınıflar ise mısır sağlıklı, üzüm yaprağı yanıklığı, biber çanı, bakteriyel nokta, ahududu sağlıklı, soya fasulyesi sağlıklı, kabak Külleme, çilek sağlıklı olmuştur. F1 Değeri: %100,00 ile en yüksek F1 değeri sınıflar ise mısır sağlıklı ve üzüm sağlıklı yapraklardır. Modelden elde edilen sonuçlar karmaşıklık matrisinde verilmiştir. Bu matris hangi hastalığın hangi hastalıklarla karıştırıldığına dair detaylı bilgiler vermektedir. Önerilen modelin yanlış sınıflandırma sınıfları incelendiğinde birbirine benzeyen yapraklar arasında karışıklığın olduğu görülmektedir. Özellikle Domates Erken Yanıklık, Domates Geç Yanıklık, Domates Septoria Yaprak

Lekesi ve Domates Yaprak Küfüne ait sınıflarda karışıklıklar oluşmuştur. Yanlış sınıflandırma yapılan yapraklar hastalıkların üzerinde oluşturduğu lekeler, renk değişimleri, dokularda meydana gelen bozulmalar birbirine benzer görseleliğe sahip olduğu saptanmaktadır. Mısır bitkisine ait hastalıklar arasındaki sınıflarda da benzer bir durum ortaya çıkmaktadır. Mısır Gri Yaprak Lekesi, Mısır Kuzey Yaprak Yanıklığı ve Mısır Yaygın Pas sınıfların yanlış tespit edildiği görülmüştür. Bu hastalıkların görsel benzerlikleri arasında ayırım yapması zorlaşmaktadır. Bunun dışında, bazı hastalıkların sağlıklı yapraklarla veya birbirinden oldukça farklı semptomlara sahip diğer hastalıklarla karıştırılmadığı, yani modelin bu tür örneklerde yüksek doğruluk sağladığı görülmektedir. Özellikle sağlıklı yapraklar ve belirgin semptomlara sahip hastalıklar, model tarafından neredeyse hatasız şekilde sınıflandırılmıştır. Modelin genel olarak ayırt edici ve belirgin semptomlara sahip sınıflarda başarılı olduğu görülmüştür. Sonuç olarak modelin hata yaptığı örneklerin büyük çoğunluğu, semptomları birbirine yakın ve görsel olarak ayırt edilmesi güç hastalıklar arasında yoğunlaşmaktadır. Bu bulgu, bitki hastalıklarının otomatik tespitinde, özellikle benzer semptomlara sahip hastalıklar için daha gelişmiş öznetelik çıkarımı, ek veri artırma veya uzman destekli segmentasyon gibi yöntemlerin kullanılmasının model performansını artırabileceğini göstermektedir. Yapılan bu çalışmada elde edilen sonuçlar genel bazı değerlendirildiğinde yanlış tespit oranının oldukça düşük olduğu ve Vit 16B modelinin öznetelikleri doğru şekilde çıkararak yüksek başarımlar elde edildiği gösterilmiştir.

Çizelge-8: Önerilen Vit 16B Segment Modeli ile Elde Edilen Karmaşıklık Matrisi Sonuçları

| S/N | 1   | 2   | 3   | 4   | 5   | 6   | 7   | 8   | 9   | 10  | 11  | 12  | 13  | 14  | 15  | 16  | 17  | 18  | 19  | 20  | 21  | 22  | 23  | 24  | 25  | 26  | 27 | 28  | 29 | 30 | 31 | 32 | 33 | 34 | 35 | 36 |
|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|----|-----|----|----|----|----|----|----|----|----|
| 1   | 499 | 1   | 0   | 2   | 0   | 0   | 0   | 3   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 3   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 1  | 0  | 0  | 1  | 0  | 0  | 0  |    |
| 2   | 1   | 495 | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 3   | 0   | 0   | 378 | 0   | 0   | 0   | 0   | 5   | 1   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 1  | 0  | 2  | 0  | 0  |    |
| 4   | 1   | 0   | 0   | 492 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 6   | 0   | 0  | 0   | 1  | 1  | 0  | 0  | 0  | 0  | 0  |    |
| 5   | 1   | 0   | 0   | 3   | 449 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 1   | 0   | 0   | 2   | 0   | 3   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 2  | 1  | 0  | 0  | 1  | 0  |    |
| 6   | 0   | 0   | 0   | 0   | 0   | 456 | 0   | 0   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 1   | 2   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 7   | 0   | 0   | 0   | 0   | 0   | 0   | 388 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 1   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 8   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 355 | 0   | 0   | 19  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 1  | 0  | 0  | 0  | 0  |    |
| 9   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 10  | 458 | 0   | 9   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 1  | 0  | 0  | 0  | 0  |    |
| 10  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 464 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 11  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 30  | 7   | 0   | 430 | 0   | 0   | 0   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 12  | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 467 | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 13  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 5   | 478 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 14  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 423 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 15  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 419 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 16  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 483 | 2   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 17  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 390 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 1  | 0  | 0  | 0  | 0  |    |
| 18  | 0   | 0   | 0   | 2   | 0   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 1   | 8   | 429 | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 19  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 465 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 20  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 2   | 483 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 21  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 1   | 0   | 1   | 0   | 461 | 0   | 1   | 0   | 0   | 0   | 0   | 0  | 0   | 4  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 22  | 0   | 0   | 0   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 3   | 0   | 420 | 5   | 0   | 4   | 0   | 0   | 0  | 0   | 0  | 1  | 0  | 0  | 0  | 0  | 0  |    |
| 23  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 5   | 1   | 464 | 0   | 0   | 0   | 0   | 0  | 2   | 1  | 12 | 0  | 0  | 0  | 0  | 0  |    |
| 24  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 445 | 0   | 0   | 1   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 25  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 494 | 0   | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 26  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 433 | 0   | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 27  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 455 | 0  | 0   | 0  | 0  | 0  | 0  | 0  | 0  | 0  |    |
| 28  | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 1   | 0   | 7   | 0   | 2   | 1   | 0   | 0   | 7   | 0   | 1   | 0   | 0   | 0   | 0   | 0  | 422 | 1  | 3  | 0  | 1  | 0  | 2  | 0  | 0  |



kalitesini artırarak modellerin başarı oranlarını nasıl iyileştirebileceğine dair önemli bir bulgu sunmaktadır.

SqueezeNet gibi daha az katmanlı ve daha az karmaşık modellerin, önerilen ViT 16B ve diğer daha derin modellerle kıyaslandığında daha düşük başarımlar göstermesi, model karmaşıklığı ve başarımlar arasındaki ilişkiye işaret etmektedir. Hafif modellerin pratik avantajlarına rağmen, daha karmaşık derin öğrenme modellerinin (örneğin ResNet101, Vgg16) daha yüksek doğruluk oranlarına ulaşması, sınıflandırma problemlerinde daha derin ağların önemini ortaya koymaktadır. Ancak, bu durum her zaman daha karmaşık bir modelin daha iyi olduğu anlamına gelmemekte; belirli veri setlerinde başarımlar-fayda dengesi düşünülerek karar verilmesi gerekmektedir.

Literatürde kullanılan farklı dönüştürücü modeller yer almaktadır. Bunlar arasında DeiT(data-efficient Image Dönüştürücü) daha az veri ile yüksek başarımlar hedeflerken Swin Dönüştürücü görüntü parçalara ayrılarak işlendiğinde daha iyi sonuçlar vermektedir. T2T-ViT ise düşük parametre iyi daha yüksek başarımlar sağlamaya çalışan bir modeldir. Mobil cihazlar için MobilViT düşük donanım maliyeti ile hesaplama yapmaktadır. Bu çalışma için dönüştürücü modeller karşılaştırıldığında kullanmış olduğumuz veri setinin büyük olması, başarımların daha yüksek olması sebebiyle tercih edilmiştir. Uygulama alanına göre farklı türde dönüştürücü modeller tercih edilebilir.

ViT 16B'nin diğer modellere göre sağladığı %99.87'lik yüksek başarımla daha karmaşık yaprak hastalıklarını bile doğru tespit edebilmesi, bu modelin yüksek genelleme kapasitesine sahip olduğunu göstermektedir. Modelin özellikle sağlıklı mısır ve üzüm yapraklarını %100 doğruluk oranıyla tespit edebilmesi, hastalık ve sağlıklı sınıflar arasında net bir ayrım yapma konusunda etkin olduğunu vurgulamaktadır. Bu tür başarımlar, modelin tarımsal uygulamalarda pratik fayda sağlayabileceğini ve hastalıkların erken teşhisinde etkili bir çözüm olabileceğini işaret etmektedir. %100'e yakın kesinlik ve duyarlılık oranına sahip sınıfların tespit edilmesi, modelin pek çok sınıflarda oldukça yüksek güvenilirlikle çalıştığını göstermektedir. ViT 16B modeli daha yüksek parametre sayısına sahip olduğundan eğitim ve sınav süreleri uzun olmaktadır. Ancak sağlamış olduğu doğruluk oranı bu maliyeti karşılamaktadır. Bu, tarım sektöründe, özellikle kritik bitki hastalıklarının erken teşhisi ve önlenmesinde kullanıldığında büyük bir etki oluşturabilir. Yüksek kesinlik ve duyarlılık oranlarına sahip sonuçların güvenilirliği, ürün yetiştiriciliğinde kayıpların azaltılmasını ve daha verimli bir tarım sürecini mümkün kılabilir. Örneğin, çiftçilerin hastalıkların yayılmasını önlemesi ve daha verimli bir hasat dönemi geçirmesi bu gibi modellerin yaygın uygulaması ile desteklenebilir.

Tarla koşullarındaki değişen ışık ve arka plan görüntüsü önerilen yöntemdeki HSV tabanlı segmentasyon sürecini olumsuz etkileyebilir. Bu durum yaprak görüntülerinin tam olarak ortaya konmamasına neden olmaktadır. Çalışmada bu tür durumda olan ender sayıdaki görüntü veri setinden çıkarılmıştır. Gelecek çalışmalar içerisinde histogram dengeleme veya CLAHE gibi yöntemlerle bu sorunun

üstesinden gelebilecek ve bu tür sorunların üstesinden gelinebileceği düşünülmektedir. Modelin 86 milyon üzerindeki parametre sayısı ile donanım gereksinimi yüksektir. Bu durum yöntemin mobil veya düşük donanımlı cihazlarla kullanılması için optimizasyona ihtiyaç duyduğunu göstermektedir. Daha hafif ViT modelleri(T2T-ViT ve MobilViT) ile düşük donanımlı cihazlara entegrasyonu sağlanabilir. Alternatif olarak bulut tabanlı çözümler kullanılarak gerçek zamanlı çözümlerle tarla ortamda uygulanması sağlanabilir. Ayrıca önerilen model tarla koşullarında çalışırken bir ya da birkaç yaprağın kontrolünü yapacağından sınav süresi oldukça kısa olacaktır. Modelin eğitilmiş hali kullanılmasıyla tarla koşullarında önemsenebilecek bir gecikme oluşturmaz.

Bununla birlikte, derin öğrenme modellerinin sınırlamaları da göz önünde bulundurulmalıdır. Model performansı, kullanılan veri setinin büyüklüğü, veri çeşitliliği ve ön işleme adımlarının kalitesine bağlı olarak değişebilir. Bu nedenle, gelecekteki çalışmalar, veri setinin genişletilmesi, veri artırma teknikleri ve hibrit modellerin kullanılması gibi yöntemlerle model performansının daha da iyileştirilmesine odaklanabilir. Ayrıca, önerilen yöntemin gerçek zamanlı tarım uygulamalarına entegrasyonu ve diğer tarımsal verilerle birleşik olarak değerlendirilmesi daha kapsamlı sonuçlar sunabilir. Bu çalışma sadece PlantVillage veri setine ait görüntüler üzerinde çalışılmıştır. Gerçek tarla koşullarındaki değişen ışık, gölge, rüzgar gibi faktörler modellerin performansını olumsuz yönde etkileyebilir. Bu durum gözetilerek ilerleyen çalışmalarda farklı veri setleri ve farklı hava koşullarına uygun veri setleri ile çalışma yapılması planlanmaktadır.

## Kaynakça

- [1] Eren, M. V., "Nüfus Artışı ile Kalkınma Arasındaki İlişki: Sahra-Altı Afrika Ülkeleri Üzerine Ampirik Bir Analiz," Uluslararası İktisadi ve İdari İncelemeler Dergisi, no. 27, 2020, pp. 141-158, doi: <https://doi.org/10.18092/ulikidince.586948>.
- [2] Kılavuz, E. and Erdem, İ., "Dünyada tarım 4.0 uygulamaları ve Türk tarımının dönüşümü," Social Sciences, vol. 14, no. 4, 2019, pp. 133-157.
- [3] Gövez, E., "Tarım Sektörüne Yenilikçi Bir Bakış Açısı: Tarım 4.0," Sosyal Sorunlar (Teoriler, Politikalar, Uygulamalar), 2023, p. 87.
- [4] Doğan, F. and Türkoğlu, İ., "Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme," Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, vol. 10, no. 2, 2019, pp. 409-445, doi: <https://doi.org/10.24012/dumf.411130>.
- [5] Bayram, C. A., "The Effects of Mycorrhiza and Seaweed Applications on Seedling Growth Parameters: Tomato and Pepper," Communications in Soil Science and Plant Analysis, vol. 55, no. 10, 2024, pp. 1375-1389, doi: <https://doi.org/10.1080/00103624.2024.2305844>.
- [6] YILDIZ, H., İlker, E., and YILDIRIM, A., "Bazı silajlık mısır (Zea mays) çeşit ve çeşit adaylarının verim ve kalite özelliklerinin belirlenmesi," Ziraat Fakültesi Dergisi, vol. 12, no. 2, 2017, pp. 81-89.
- [7] Büyük, G., Bayram, C. A., İnan, M., and Kırpık, M., "The effect of organic and inorganic fertilizers on plant nutrient content and agronomic performance of stevia," Journal of Plant Nutrition,

- vol. 45, no. 15, 2022, pp. 2303-2314, doi: <https://doi.org/10.1080/01904167.2022.2063739>.
- [8] Özdemir, R. and Demirbaş, N., "Meyve ve sebze üretiminde ortaya çıkan kayıplar üzerinde etkili olan faktörler: İzmir ili örneği," *Mediterranean Agricultural Sciences*, vol. 33, no. 1, 2020, pp. 85-91, doi: <https://doi.org/10.29136/mediterranean.659011>.
- [9] ERTAŞ, B., "Tarım 4.0 ile sürdürülebilir bir gelecek," *Icontech International Journal*, vol. 4, no. 1, 2020, pp. 1-12, doi: <https://doi.org/10.46291/ICONTECHvol4iss1pp1-12>.
- [10] Doğan, F. and Türkoğlu, İ., "Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması," *Sakarya University Journal of Computer and Information Sciences*, vol. 1, no. 1, 2018, pp. 10-21.
- [11] Tay, Y., Dehghani, M., Bahri, D., and Metzler, D., "Efficient transformers: A survey," *ACM Computing Surveys*, vol. 55, no. 6, 2022, pp. 1-28.
- [12] Solak, M., "Moleküler Biyoloji ve Genetik: Sağlık Alanında ve Biyoteknolojide İleri Uygulamalar," ed: Türkiye Bilimler Akademisi, 2023.
- [13] Koçak, R., "Beşinci sanayi devrimi toplum 5.0 ve yapay zekâ kültürü," *Uluslararası Halkbilimi Araştırmaları Dergisi*, vol. 3, no. 5, 2020, pp. 1-17.
- [14] Güzel, B. and Okatan, E., "Tarım Ve Yapay Zekâ," *Yapay Zekânın Değiştirdiği Dinamikler*, 2022, p. 199.
- [15] Doğan, F., Oyucu, S., Bicer, E., and Aksoz, A., "Deep learning models for damage type detection in wind turbines," *PeerJ Computer Science*, vol. 11, 2025, p. e3163, doi: <https://doi.org/10.7717/peerj-cs.3163>.
- [16] Doğan, F., Aktaş, M., and Gürsoy, M. İ., "Classification of Skin Diseases with Different Deep Learning Models and Comparison of the Performances of the Models," *Türk Doğa ve Fen Dergisi*, vol. 13, no. 3, 2024, pp. 117-123, doi: <https://doi.org/10.46810/tdfd.1502471>.
- [17] Sam, S. M., Kamardin, K., Sjarif, N. N. A., and Mohamed, N., "Offline signature verification using deep learning convolutional neural network (CNN) architectures GoogLeNet inception-v1 and inception-v3," *Procedia Computer Science*, vol. 161, 2019, pp. 475-483, doi: <https://doi.org/10.1016/j.procs.2019.11.147>.
- [18] Vaswani, A. et al., "Attention is all you need," *Advances in neural information processing systems*, vol. 30, 2017.
- [19] Dosovitskiy, A. et al., "An image is worth 16x16 words: Transformers for image recognition at scale," *arXiv preprint arXiv:2010.11929*, 2020.
- [20] Zhou, L., Xiao, Q., Taha, M. F., Xu, C., and Zhang, C., "Phenotypic analysis of diseased plant leaves using supervised and weakly supervised deep learning," *Plant Phenomics*, vol. 5, 2023, p. 0022, doi: <https://doi.org/10.34133/plantphenomics.0022>.
- [21] Pavithra, A. and Kalpana, G., "Automated Leaf Disease Identification and Analysis in Precision Agriculture based on Deep Learning," in *2023 5th International Conference on Smart Systems and Inventive Technology (ICSSIT)*, 2023: IEEE, pp. 1363-1367, doi: 10.1109/ICSSIT55814.2023.10061149.
- [22] Agarwal, M., Gill, K. S., Upadhyay, D., and Devliyal, S., "From Pixels to Insights: Harnessing Deep Learning for Accurate Plant Pathology Diagnosis," in *2024 International Conference on Intelligent Systems for Cybersecurity (ISCS)*, 2024: IEEE, pp. 1-5, doi: <https://doi.org/10.1109/ISCS61804.2024.10581100>.
- [23] Eunice, J., Popescu, D. E., Chowdary, M. K., and Hemanth, J., "Deep learning-based leaf disease detection in crops using images for agricultural applications," *Agronomy*, vol. 12, no. 10, 2022, p. 2395, doi: <https://doi.org/10.3390/agronomy12102395>.
- [24] Tran-Anh, D., Nguyen Huu, Q., Nguyen Thi Phuong, T., and Dao Thi Thuy, Q., "Leaf disease classification with Multiple-model deep learning," *Journal of Intelligent & Fuzzy Systems*, no. Preprint, 2024, pp. 1-13, doi: <https://doi.org/10.3233/JIFS-235940>.
- [25] Balamurugan, M., Srividhya, N., Indhumathi, G., Arul, V., and Kalaiarasi, K., "Deep Learning Innovations for Improved Plant Leaf Disease Detection in Smart Agriculture," in *2024 Second International Conference on Data Science and Information System (ICDSIS)*, 2024: IEEE, pp. 1-6, doi: <https://doi.org/10.1109/ICDSIS61070.2024.10594188>.
- [26] Singh, G. and Yogi, K. K., "Performance evaluation of plant leaf disease detection using deep learning models," *Archives of Phytopathology and Plant Protection*, vol. 56, no. 3, 2023, pp. 209-233, doi: <https://doi.org/10.1080/03235408.2023.2183792>.
- [27] Sucharitha, G., Sirisha, M., Pravalika, K., and Gayathri, K. N., "A Study on the Performance of Deep Learning Models for Leaf Disease Detection," *EAI Endorsed Transactions on Internet of Things*, vol. 10, 2024.
- [28] Mohanty, S. P., Hughes, D. P., and Salathé, M., "Using deep learning for image-based plant disease detection," *Frontiers in plant science*, vol. 7, 2016, p. 1419, doi: <https://doi.org/10.3389/fpls.2016.01419>.
- [29] Siddharth, S. C., Singh, U., Kaul, A., and Jain, S., "A database of leaf images: practice towards plant conservation with plant pathology," *Mendeley Data*, 2019.
- [30] Kour, V. P. and Arora, S., "Plantaek: A leaf database of native plants of jammu and kashmir," in *Recent Innovations in Computing: Proceedings of ICRC 2021, Volume 1*: Springer, 2022, pp. 359-368.
- [31] Singh, D., Jain, N., Jain, P., Kayal, P., Kumawat, S., and Batra, N., "PlantDoc: A dataset for visual plant disease detection," in *Proceedings of the 7th ACM IKDD CoDS and 25th COMAD*, 2020, pp. 249-253.
- [32] Durieux, A. "Plant Pathology 2021 - FGVC8." *Kaggle Competition*. <https://www.kaggle.com/c/plant-pathology-2021-fgvc8/overview> (accessed 2021).
- [33] Wiesner-Hanks, T. et al., "Image set for deep learning: field images of maize annotated with disease symptoms," *BMC research notes*, vol. 11, 2018, pp. 1-3, doi: <https://doi.org/10.1186/s13104-018-3548-6>.
- [34] Rauf, H. T., Saleem, B. A., Lali, M. I. U., Khan, M. A., Sharif, M., and Bukhari, S. A. C., "A citrus fruits and leaves dataset for detection and classification of citrus diseases through machine learning," *Data in brief*, vol. 26, 2019, p. 104340, doi: <https://doi.org/10.1016/j.dib.2019.104340>.
- [35] Sethy, P. K., Barpanda, N. K., Rath, A. K., and Behera, S. K., "Deep feature based rice leaf disease identification using support vector machine," *Computers and Electronics in Agriculture*, vol. 175, 2020, p. 105527, doi: <https://doi.org/10.1016/j.compag.2020.105527>.
- [36] Jepkoech, J., Mugo, D. M., Kenduiyo, B. K., and Too, E. C., "Arabica coffee leaf images dataset for coffee leaf disease detection and classification," *Data in brief*, vol. 36, 2021, p. 107142.
- [37] Mwebaze, E., Gebru, T., Frome, A., Nsumba, S., and Tusubira, J., "iCassava 2019 fine-grained visual categorization challenge,"

- arXiv preprint arXiv:1908.02900, 2019, doi: <https://doi.org/10.48550/arXiv.1908.02900>.
- [38] Prajapati, H. B., Shah, J. P., and Dabhi, V. K., "Detection and classification of rice plant diseases," *Intelligent Decision Technologies*, vol. 11, no. 3, 2017, pp. 357-373, doi: <https://doi.org/10.3233/IDT-170301>.
- [39] Pacal, I., "Enhancing crop productivity and sustainability through disease identification in maize leaves: Exploiting a large dataset with an advanced görsel dönüştürücü model," *Expert Systems with Applications*, vol. 238, 2024, p. 122099, doi: <https://doi.org/10.1016/j.eswa.2023.122099>.
- [40] Li, L.-H. and Tanone, R., "Disease identification in potato leaves using swin dönüştürücü," in *2023 17th International Conference on Ubiquitous Information Management and Communication (IMCOM)*, 2023: IEEE, pp. 1-5, doi: <https://doi.org/10.1109/IMCOM56909.2023.10035609>.
- [41] Bhowmik, A. C., Ahad, M. T., Emon, Y. R., Ahmed, F., Song, B., and Li, Y., "A customised Vision Dönüştürücü for accurate detection and classification of Java Plum leaf disease," *Smart Agricultural Technology*, vol. 8, 2024, p. 100500, doi: <https://doi.org/10.1016/j.atech.2024.100500>.
- [42] Zhu, W., Sun, J., Wang, S., Shen, J., Yang, K., and Zhou, X., "Identifying field crop diseases using dönüştürücü -embedded convolutional neural network," *Agriculture*, vol. 12, no. 8, 2022, p. 1083, doi: <https://doi.org/10.3390/agriculture12081083>.
- [43] Hossain, S., Tanzim Reza, M., Chakrabarty, A., and Jung, Y. J., "Aggregating different scales of attention on feature variants for tomato leaf disease diagnosis from image data: a dönüştürücü driven study," *Sensors*, vol. 23, no. 7, 2023, p. 3751, doi: <https://doi.org/10.3390/s23073751>.
- [44] Ali, M., Salma, M., El Haji, M., and Jamal, B., "Plant disease detection using görsel dönüştürücüs," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 15, no. 2, 2025, pp. 2334-2344, doi: <http://doi.org/10.11591/ijece.v15i2.pp2334-2344>.
- [45] Hemalatha, S. and Jayachandran, J. J. B., "A multitask learning-based görsel dönüştürücü for plant disease localization and classification," *International Journal of Computational Intelligence Systems*, vol. 17, no. 1, 2024, p. 188.
- [46] De Silva, M. and Brown, D., "Plant disease detection using görsel dönüştürücüs on multispectral natural environment images," in *2023 International Conference on Artificial Intelligence, Big Data, Computing and Data Communication Systems (icABCD)*, 2023: IEEE, pp. 1-6, doi: <https://doi.org/10.1109/icABCD59051.2023.10220517>.
- [47] Thakur, P. S., Chaturvedi, S., Khanna, P., Sheorey, T., and Ojha, A., "Vision dönüştürücü meets convolutional neural network for plant disease classification," *Ecological Informatics*, vol. 77, 2023, p. 102245, doi: <https://doi.org/10.1016/j.ecoinf.2023.102245>.
- [48] Hughes, D. and Salathé, M., "An open access repository of images on plant health to enable the development of mobile disease diagnostics," *arXiv preprint arXiv:1511.08060*, 2015, doi: <https://doi.org/10.48550/arXiv.1511.08060>.
- [49] Krizhevsky, A., Sutskever, I., and Hinton, G. E., "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, 2017, pp. 84-90.
- [50] Simonyan, K. and Zisserman, A., "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [51] Iandola, F. N., "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size," *arXiv preprint arXiv:1602.07360*, 2016.
- [52] He, K., Zhang, X., Ren, S., and Sun, J., "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [53] Szegedy, C. et al., "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.
- [54] Doğan, F. and Türkoğlu, İ., "Comparison of deep learning models in terms of multiple object detection on satellite images," *Journal of Engineering Research*, vol. 10, no. 3, 2022, pp. 89-108, doi: <https://doi.org/10.36909/jer.12843>.