



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**TRANSFER ÖĞRENME TABANLI
AÇIKLANABİLİR DERİN ÖĞRENME
YÖNTEMLERİ KULLANILARAK BİTKİ
HASTALIKLARININ SINIFLANDIRILMASI**

Ahmet Enes KILIÇ

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

08-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Ahmet Enes KILIÇ tarafından hazırlanan “Transfer Öğrenme Tabanlı Açıklanabilir Derin Öğrenme Yöntemleri Kullanılarak Bitki Hastalıklarının Sınıflandırılması” adlı tez çalışması 02/08/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Halife KODAZ

.....

Danışman

Dr. Öğr. Üyesi Murat KARAKOYUN

.....

Üye

Prof. Dr. Sabri KOÇER

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun/.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Ahmet Enes KILIÇ

Tarih: 02.08.2024

ÖZET

YÜKSEK LİSANS TEZİ

TRANSFER ÖĞRENME TABANLI AÇIKLANABİLİR DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK BİTKİ HASTALIKLARININ SINIFLANDIRILMASI

Ahmet Enes KILIÇ

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Murat KARAKOYUN

2024, 55 Sayfa

Jüri

Dr. Öğr. Üyesi Murat KARAKOYUN

Prof. Dr. Sabri KOÇER

Prof. Dr. Halife KODAZ

Bitki hastalıkları, küresel tarıma ciddi zararlar veren temel sorunlardan biridir. Bu zararları önlemek adına hastalıkların erken teşhisi büyük önem taşımaktadır. Ancak, manuel teşhis süreci hem zorlu hem de zaman alıcıdır. Bu nedenle, bitki hastalıklarının otomatik tespiti için derin öğrenme yöntemleri kullanılmaktadır. Bu çalışmada, PlantVillage veri seti kullanılarak bitki görüntülerinden hastalık sınıflandırılması amacıyla ResNet152, VGG16, EfficientNet-B0, EfficientNet-B1, DenseNet201, GoogLeNet ve Vision Transformers olmak üzere yedi farklı derin öğrenme yöntemi eğitilmiştir. Modellerin performansları karşılaştırılmış ve açıklanabilir yapay zekâ yöntemleriyle karar verme süreçleri incelenmiştir. Bu doğrultuda, modellerin karar mekanizmalarını görselleştiren açıklanabilirlik haritaları oluşturulmuş ve bu haritalar üzerinden modellerin hangi özelliklere dayanarak karar verdikleri analiz edilmiştir. PlantVillage veri seti üzerinde %99,81 doğruluk, %99,74 hassasiyet, %99,74 duyarlılık ve %99,74 f1 skoru ile DenseNet201 en başarılı model olarak öne çıkmıştır. En düşük performansı ise %99,27 doğruluk, %99,13 hassasiyet, %99,10 duyarlılık ve %99,11 f1 skoru ile ViT Large 32 modeli göstermiştir. Farklı modellerin güçlü ve zayıf yönleri değerlendirilerek belirli bir uygulama için en uygun modelin seçilebileceği sonucuna varılmaktadır. Ayrıca derin öğrenme yöntemlerinin gerçek dünyadaki etkinliği ve verimliliği, Kaggle'da 2020 ve 2021 yıllarında düzenlenen Plant Pathology yarışmalarında yer alan, gerçek hayattan alınan elma bitkisi görüntüleri ile test edilmiştir. Laboratuvar ortamında elde edilen görüntüler üzerinde yüksek doğruluk ve güvenilirlikle elde edilen başarılı modellerin, gerçek dünya verileri üzerinde aynı başarıyı gösteremediği ortaya konmuştur. Bu çalışma, veri seti çeşitliliği ve karmaşıklığının model performansı üzerindeki kritik etkisini vurgulamakta ve laboratuvar verileri ile gerçek dünya verileri arasındaki farklılıkların derinlemesine incelenmesi gerektiğini göstermektedir.

Anahtar Kelimeler: Bitki Hastalığı, Derin Öğrenme, PlantVillage, Sınıflandırma, Tarım

ABSTRACT

MS THESIS

CLASSIFICATION OF PLANT DISEASES USING EXPLAINABLE DEEP LEARNING METHODS BASED ON TRANSFER LEARNING

Ahmet Enes KILIÇ

**THE DEGREE OF MASTER OF SCIENCE
IN COMPUTER ENGINEERING**

Advisor: Asst. Prof. Dr. Murat KARAKOYUN

2024, 55 Pages

Jury

Asst. Prof. Dr. Murat KARAKOYUN

Prof. Dr. Sabri KOÇER

Prof. Dr. Halife KODAZ

Plant diseases represent a major challenge to global agriculture, causing significant damage. Early detection of these diseases is crucial to mitigating their impact. However, manual diagnosis is both challenging and time-consuming. As a result, deep learning methods are increasingly being utilized for the automatic detection of plant diseases. In this study, seven different deep learning models—ResNet152, VGG16, EfficientNet-B0, EfficientNet-B1, DenseNet201, GoogLeNet, and Vision Transformers—were trained for the classification of plant diseases using images from the PlantVillage dataset. The performance of these models was compared, and their decision-making processes were analyzed using explainable artificial intelligence (XAI) methods. In this context, explainability maps were generated to visualize the decision mechanisms of the models, and these maps were analyzed to determine the features on which the models based their decisions. Among the models, DenseNet201 achieved the highest performance on the PlantVillage dataset with an accuracy of 99.81%, precision of 99.74%, recall of 99.74%, and f1-score of 99.74%. The ViT Large 32 model, on the other hand, demonstrated the lowest performance with an accuracy of 99.27%, precision of 99.13%, recall of 99.10%, and f1-score of 99.11%. By evaluating the strengths and weaknesses of different models, it is possible to select the most suitable model for a specific application. The real-world effectiveness and efficiency of these deep learning methods were tested using apple plant images from the Plant Pathology competitions held on Kaggle in 2020 and 2021. It was found that models that performed well with high accuracy and reliability in controlled laboratory environments did not achieve the same success with real-world data. This study underscores the critical impact of dataset diversity and complexity on model performance, highlighting the need for an in-depth examination of the differences between laboratory data and real-world data.

Keywords: Agriculture, Classification, Deep Learning, Plant Disease, PlantVillage

ÖNSÖZ

Bu çalışmam boyunca bana gösterdikleri sevgi, sabır ve destekle her an yanımda olan canım kızım Sevde KILIÇ ve sevgili eşim Fatma Zehra KILIÇ'a en derin teşekkürlerimi sunarım. Onların varlığı, bu süreci daha anlamlı kılmıştır. Ailemin her bir ferdi, gösterdikleri anlayış ve motivasyon ile bu çalışmanın arkasındaki en büyük güç kaynağım olmuştur.

Akademik yolculuğumda her zaman rehberlik eden ve engin bilgisiyle bana yol gösteren değerli danışman hocam Dr. Öğr. Üyesi Murat KARAKOYUN'a teşekkürü bir borç bilirim. Kendisi, çalışmamın her aşamasında verdiği kıymetli geri bildirimler ve destekle, bu çalışmanın gelişimine büyük katkı sağlamıştır.

Ahmet Enes KILIÇ
KONYA-2024



İÇİNDEKİLER

ÖZET	vii
ABSTRACT.....	iv
ÖNSÖZ	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
1.1. Amaç ve Hedefler	3
1.2. Tez Organizasyonu	4
2. KAYNAK ARAŞTIRMASI	5
3. MATERYAL VE YÖNTEM.....	9
3.1. Veri Setleri	9
3.1.1. PlantVillage	9
3.1.2. Plant Pathology 2020 ve Plant Pathology 2021	11
3.2. Veri Ön işleme	13
3.2.1. Veri Keşfi.....	13
3.2.2. Veri Normalizasyonu	14
3.2.3. Veri Artırma.....	14
3.2.4. Veri Ayırıştırma	14
3.3. Derin Öğrenme Modelleri.....	16
3.3.1. ResNet152.....	19
3.3.2. VGG16.....	20
3.3.3. EfficientNet.....	21
3.3.4. DenseNet201.....	22
3.3.5. GoogLeNet.....	23
3.3.6. Vision Transformers Large 32	25
3.4. Açıklanabilirlik	26
3.4.1. GradCAM	29
3.4.2. GradCAM++	30
3.4.3. XGradCAM	30
3.4.4. EigenCAM	30
3.4.5. LayerCAM	30
3.5. Değerlendirme Metrikleri	31
3.5.1. Karmaşıklık Matrisi	31
3.5.2. Doğruluk	32
3.5.3. Hassasiyet	32
3.5.4. Duyarlılık	32
3.5.5. F1 Skor.....	33
3.6. Donanım.....	33
3.7. Yapay Zekâ Süreci.....	34

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	37
4.1. Deneysel Yöntemler	37
4.2. Deney 1 Sonuçlar.....	38
4.3. Deney 2-3 Sonuçlar	39
4.3. Deney 4-5 Sonuçlar	40
4.4. Açıklanabilirlik Sonuçları.....	42
5. SONUÇLAR VE ÖNERİLER	46
5.1 Sonuçlar	46
5.2 Öneriler	46
6. KAYNAKLAR	50



SİMGELER VE KISALTMALAR

Kısaltmalar

CNN	Convolution Neural Network
SGD	Stochastic Gradient Descent
PCA	Principal Component Analysis
RGB	Red-Green-Blue
XAI	Explainable Artificial Intelligence (Açıklanabilir Yapay Zekâ)
NLP	Natural Language Processing (Doğal Dil İşleme)
MLP	Multi Layer Perceptron
ResNet	Residual Networks
ReLU	Rectified Linear Unit
MBConv	Mobile Inverted Bottleneck Convolution
DenseNet	Densely Connected Convolutional Networks
ViT	Vision Transformers
CAM	Class Activation Mapping (Sınıf Aktivasyon Haritaları)
Grad-CAM	Gradient-weighted Class Activation Mapping
Grad-CAM++	Gradient-weighted Class Activation Mapping++
XGrad-CAM	eXplanation Gradient-weighted Class Activation Mapping
Eigen-CAM	Eigen Class Activation Mapping
Layer-CAM	Layer-wise Class Activation Mapping
TP	True Positive
TN	True Negative
FP	False Positive
FN	False Negative
CPU	Central Processing Unit

GPU	Graphics Processing Unit
RAM	Random Access Memory
CUDA	Compute Unified Device Architecture



1. GİRİŞ

Tarım alanında bitki hastalıklarının erken teşhisi bitki sağlığı ve verimi açısından oldukça önemlidir. Bitki hastalığının göz önüne alınmadığı durumda hem ekonomik olarak çiftçi etkilenmekte hem de iklimsel anlamda dünya değişmektedir. Son zamanlarda internetin gelişmesi ile karar destek sistemleri, makine öğrenimi algoritmaları vb. gibi yöntemler bitki hastalığının otomatik tespiti gibi çalışmalarda kullanılmaya başlanmıştır (Ouhami ve ark., 2021). Ancak veri yetersizliği ve uygun olmayan veri durumlarından ötürü gerçek veriler üzerinde başarılı sonuçlar elde edilememektedir. Yakın dönemde gelişen derin öğrenme ile özniteliklerin otomatik çıkarımı sağlanmış ve endüstri, tıp, sanayi gibi alanlarda sıklıkla gerçek dünya problemlerinde kullanılmaya başlanmıştır. Bu durum tarım alanına da sirayet etmiş ve tarımda derin öğrenme kullanımı giderek artmıştır (Kamilaris ve ark., 2018). Özellikle derin öğrenme teknikleri, görüntü işleme ve veri analizi alanında çığır açıcı gelişmelere imza atarak, bitki hastalıklarının teşhisinde kullanılmaktadır.

Bitki hastalıkları dünya tarımsal kalkınmasına verilen zararın ana nedenlerinden biridir (Nazarov ve ark., 2020). Bitki hastalıklarının erken teşhisi bitki sağlığı ve verimi açısından oldukça önemlidir. Bitki hastalıklarının tespitinde insan gücü yerine yapay zekâ gibi yenilikçi teknolojiler erken teşhisi kolaylaştırmaktadır. Akıllı tarımın gelişmesiyle birlikte tarım alanında yapay zekâ modellerinin geliştirilmesi amacıyla büyük hacimli bitki görüntü veri setleri literatüre kazandırılmıştır. Derin öğrenme algoritmaları, büyük miktarda görsel veriyi işleyerek bitki yapraklarındaki hastalık belirtilerini yüksek doğruluk oranlarıyla tespit edebilmekte ve sınıflandırabilmektedir (Wani ve ark., 2022). Bu teknolojiler, hastalıkların erken dönemde fark edilmesi ve doğru tedavi yöntemlerinin belirlenmesi için çiftçilere ve tarım uzmanlarına güçlü bir araç sunmaktadır.

Derin öğrenme teknikleri, bitki hastalıklarının tespitinde yüksek doğruluk oranları ve hızlı teşhis yetenekleri sunarak tarım sektöründe devrim niteliğinde yenilikler getirmektedir (Shaikh ve ark., 2022). Ancak, bu modellerin içsel çalışma prensiplerinin anlaşılabilirliği ve şeffaflığı, özellikle tarımsal uygulamalarda güvenilirlik açısından büyük önem taşımaktadır. Bu noktada, açıklanabilir derin öğrenme yöntemleri devreye girerek, modellerin karar alma süreçlerini anlamayı ve bu süreçleri tarım uzmanları ve çiftçiler için daha güvenilir hale getirmeyi amaçlamaktadır. Geleneksel derin öğrenme modellerinin en büyük dezavantajlarından biri, karar alma süreçlerinin genellikle bir "kara kutu" gibi çalışmasıdır. Modelin belirli bir sonuca nasıl ulaştığı genellikle

anlaşılmaz. Bu da kullanıcılar için belirsizlik yaratır ve güven sorunlarına yol açabilir. Açıklanabilir yapay zekâ (Explainable AI - XAI) bu sorunu çözmeyi amaçlayarak, modellerin iç işleyişini ve karar alma süreçlerini daha şeffaf hale getirmektedir. Açıklanabilir derin öğrenme yöntemleri, kullanıcıların modelin hangi özelliklere dayanarak karar verdiğini anlamalarını sağlayarak, model sonuçlarına olan güveni artırır ve daha bilinçli karar verme süreçlerine katkıda bulunur (Ras ve ark., 2022).

Açıklanabilir derin öğrenme yöntemleri, modellerin karar süreçlerini şeffaf hale getirerek kullanıcı güvenini artırırken, bu teknolojilerin gerçek dünya koşullarındaki etkinliğini değerlendirmek de gereklidir. Bu bağlamda, laboratuvar ortamında elde edilen veriler ile eğitilen modellerin gerçek dünya koşullarında nasıl performans gösterdiğini incelemek büyük önem taşımaktadır. Laboratuvar ortamında elde edilen verilerle eğitilen derin öğrenme modelleri, kontrollü ve ideal koşullar altında yüksek performans sergileyebilir. Ancak, bu modellerin gerçek dünya koşullarında uygulanabilirliğini ve başarımını değerlendirmek, pratik kullanım açısından büyük önem taşımaktadır. Gerçek dünya uygulamaları, çeşitli çevresel faktörler, veri çeşitliliği ve pratik zorluklarla karşı karşıya kalabilir. Bu nedenle, laboratuvar ortamında elde edilen görüntüler ile eğitilen modellerin tarımsal sahalarda ne kadar etkili ve güvenilir olduğu, bu tez çalışmasının önemli bir araştırma konusunu oluşturmaktadır.

Bu tez çalışmasında, laboratuvar ortamında elde edilen veriler ile eğitilen modellerin gerçek dünya koşullarında nasıl performans gösterdiği, karşılaşılan zorluklar ve elde edilen sonuçlar detaylı olarak ele alınmıştır. Ayrıca, laboratuvar ortamı ile saha koşulları arasındaki farklar ve bu farkların modellerin performansına etkisi incelenmiştir. Bu değerlendirmeler, geliştirilen teknolojilerin tarım sektöründe geniş çapta uygulanabilirliğini belirlemek ve gelecekteki iyileştirme alanlarını tespit etmek açısından kritik öneme sahiptir. Açıklanabilir derin öğrenme yöntemlerinin bitki hastalıklarının teşhisinde nasıl kullanılabileceğini ve bu teknolojilerin tarımsal uygulamalarda nasıl etkin bir şekilde hayata geçirilebileceğini göstermeyi amaçlamaktadır. Bu bağlamda, tarım sektöründe verimliliği artırmaya ve bitki hastalıklarının yönetimini iyileştirmeye yönelik önemli katkılar sunulması hedeflenmektedir.

1.1. Amaç ve Hedefler

Bu tez çalışmasının temel amacı, bitki görüntülerinden bitki hastalık sınıflandırması yapacak açıklanabilir derin öğrenme yöntemleri eğitmek ve bu yaklaşımların gerçek dünya problemlerindeki kullanılabilirliğini değerlendirmektir.

Bu kapsamda;

- Laboratuvar ve gerçek dünya veri setlerinin belirlenmesi ve veri ön işleme yöntemleri ile hazırlanması,
- Ön işlenmiş veri setleri üzerinde derin öğrenme yöntemleri eğitilerek yöntem karşılaştırması yapılması,
- Eğitilen derin öğrenme yöntemlerinin açıklanabilirlik haritalarının çıkarılması ile modellerin bitki görüntülerinde nereye bakarak tahmin yaptığının ortaya çıkarılması, böylelikle tarım uzmanlarının ve çiftçilerin bu teknolojilere olan güveninin artırılması ve etkin kullanımının sağlanması,
- Eğitilen derin öğrenme yöntemlerini gerçek dünya veri setleri üzerinde test ederek, pratikteki uygulanabilirliğinin ve verimliliğinin ölçülmesi hedeflenmektedir.

Bu amaçlar doğrultusunda çalışmada ele alınacak başlıca araştırma soruları şunlardır:

- Açıklanabilir derin öğrenme yöntemleri kullanılarak bitki hastalıklarının teşhisi nasıl geliştirilebilir?
- Bu yöntemlerin doğruluk, güvenilirlik ve genel performans seviyeleri nedir?
- Geliştirilen modellerin gerçek dünya uygulamalarında karşılaşılabileceği zorluklar ve fırsatlar nelerdir?

Bu sorulara yanıt ararken, şu hipotezler test edilecektir:

- Açıklanabilir derin öğrenme modelleri, geleneksel derin öğrenme modellerine kıyasla daha yüksek kullanıcı güveni ve kabul oranına sahiptir.
- Modelin açıklanabilirliği, teşhis doğruluğunu artırmasa da kullanıcıların karar süreçlerinde daha etkin ve bilinçli hareket etmelerini sağlar.
- Gerçek dünya uygulamalarında, açıklanabilir derin öğrenme modelleri tarımsal verimliliği ve hastalık yönetimini olumlu yönde etkiler.

1.2. Tez Organizasyonu

Tezin sonraki aşamaları aşağıdaki bölümlerden oluşmaktadır:

Kaynak Araştırması: Bu bölümde, bitki hastalıklarının tespiti için kullanılan geleneksel ve modern yöntemler, derin öğrenme teknikleri ve açıklanabilir yapay zekâ literatürü detaylı bir şekilde incelenmektedir.

Materyal ve Yöntem: Bu bölümde, araştırmada kullanılan veri setleri, derin öğrenme modelleri ve açıklanabilirlik teknikleri ayrıntılı olarak açıklanmaktadır. Ayrıca, modellerin eğitilmesi, doğrulanması ve test edilmesi süreçleri ele alınmaktadır.

Araştırma Sonuçları ve Tartışma: Bu bölümde, açıklanabilir derin öğrenme yöntemlerinin nasıl geliştirildiği ve bitki hastalıklarının teşhisinde nasıl uygulandığı detaylandırılmaktadır. Geliştirilen modellerin performans değerlendirmeleri, doğruluk oranları ve açıklanabilirlik analizleri sunulmaktadır. Çeşitli açıklanabilirlik teknikleri ve bunların tarımsal uygulamalara adaptasyonu ele alınmaktadır.

Sonuçlar ve Öneriler: Bu bölümde, araştırma bulguları tartışılmakta ve sonuçlar değerlendirilmektedir. Ayrıca, gelecekteki araştırmalar için öneriler ve bu alandaki potansiyel gelişim alanları ele alınmaktadır.

2. KAYNAK ARAŞTIRMASI

Derin öğrenme yöntemleri kullanılarak bitki hastalıklarının sınıflandırılması için hem laboratuvar hem de gerçek dünya koşullarında elde edilen açık kaynak veri setleri, literatüre kazandırılarak bu alandaki çalışmalara önemli katkılar sağlamıştır. Bu tez çalışması kapsamında, bitki görüntülerinden bitki hastalık tespiti yapabilecek açıklanabilir derin öğrenme yöntemleri geliştirilmiş ve bu yaklaşımların gerçek dünya problemlerindeki kullanılabilirliği değerlendirilmiştir. Bu amaçla, laboratuvar ortamında elde edilen veriler üzerinde model eğitimleri gerçekleştirilmiş ve modellerin gerçek dünya koşullarındaki performansları gözlemlenmiştir. Özellikle, laboratuvar ortamında elde edilen büyük hacimli açık kaynak PlantVillage veri seti (Hughes ve ark., 2015), literatürde sıklıkla kullanılmakta ve bu alandaki çalışmalara temel oluşturmaktadır.

PlantVillage veri seti kullanılarak bitki görüntülerinden derin öğrenme yöntemleri ile bitki hastalıklarının tespitinin yapılması üzerine literatüre birçok çalışma kazandırılmıştır. Saleem ve ark. (2020), iki aşamada bitki görüntülerinden hastalık sınıflandırılması için derin öğrenme yöntemlerinin karşılaştırmalı değerlendirmesini sunmaktadır. İlk aşamada, LeafNet, VGG16, OverFeat, Improved Cifar10, Inception ResNetv2, Reduced MobileNet, Modified MobileNet, ResNet50, MLCNN, Inceptionv4, Improved GoogLeNet, AlexNet, DenseNet121, MobileNet, Hybrid AlexNet with VGG, ZFNet, Cascaded AlexNet and GoogLeNet ve Xception olmak üzere 18 adet derin öğrenme yöntemi eğitilmiş ve test seti üzerinde karşılaştırmalı analiz yapılmıştır. İkinci aşamada ise en başarılı 3 model seçilmiş (Cascaded AlexNet with GoogLeNet, Improved GoogLeNet, Xception) ve modellerin optimizasyon fonksiyonları değiştirilerek karşılaştırılmaları sunulmuştur. SGD, RMSProp, Adagrad, Adamax, Adam ve Adadelta olmak üzere 6 optimizasyon yöntemi üzerinde bir karşılaştırma sunulmuştur. Atila ve ark. (2021), başarılı sonuçlar elde etmek için öznelik çıkarımının kusursuz olması gereken makine öğrenmesi yöntemleri yerine, bitki yaprak görüntülerinden hastalık sınıflandırılması için otomatik öznelik çıkarımı yapabilen CNN tabanlı modelleri tercih etmiştir. AlexNet, ResNet50, VGG16, Inceptionv3 ve EfficientNet model varyantları (B0, B1, B2, B3, B4, B5, B6, B7) olmak üzere 12 adet derin öğrenme yönteminin başarımları karşılaştırılmıştır.

Bu çalışmaların yanı sıra; derin öğrenme yöntemleri kullanılarak görüntü üzerinden önemli öznelikler çıkarılarak SVM, KNN gibi makine öğrenmesi tabanlı yöntemlere girdi olacak şekilde hibrit yaklaşımlarda izlenmektedir. Mohameth ve ark. (2020), ResNet50, VGG16, GoogLeNet olmak üzere 3 adet CNN (Convolutional Neural

Network – Evrişimli Sinir Ağı) tabanlı derin öğrenme modelini veri setinde bulunan görüntülerin özniteliklerinin çıkarımı için kullanmıştır. Derin öğrenme modelleri tarafından çıkarılan öznitelikler bitki yapraklarındaki hastalıkları sınıflandırılmak için SVM ve KNN makine öğrenmesi yöntemlerine girdi olarak sunulmuştur. Böylelikle hem derin öğrenme hem de makine öğrenmesi yöntemleri kullanılarak hibrit bir yaklaşım sunulmaktadır. Saeed ve ark. (2021), PlantVillage veri setindeki domates, mısır ve patates görüntülerinden hastalık sınıflandırması yapmak için 4 aşamalı bir geliştirme süreci sunmaktadır. İlk aşamada, CNN tabanlı bir derin öğrenme yöntemi olan VGG19 ile derin öznitelikler çıkarılmıştır. İkinci aşamada, geliştirilen paralel füzyon metodu ile çıkarılan öznitelikler birleştirilmiştir. Üçüncü aşamada, geliştirilen PLS yöntemi ile (partial least squares) en iyi öznitelikler seçilmiştir. Son aşamada, seçilen öznitelikler ile ensemble baggage tree sınıflandırıcısı eğitilerek bitki hastalıklarının sınıflandırılması yapılmıştır.

Model başarımlarının artırılması amacıyla araştırmacılar tarafından transfer öğrenme ve ensemble öğrenme yöntemlerinin etkisi ölçülmektedir. Too ve ark. (2019), bitki görüntülerindeki hastalıkların sınıflandırılmasını en hızlı şekilde yapan mimariyi seçmek için 1000 sınıfa sahip 1,2 milyon doğal görüntüleri içeren ImageNet veri setinde önceden eğitilmiş modellerden transfer öğrenme yaparak VGG16, InceptionV4, ResNet50, ResNet101, ResNet152 ve DenseNet121 derin öğrenme yöntemlerinin başarımları ve zaman karşılaştırılması verilmiştir. Vallabhajosyula ve ark. (2022), SGD, RMSPROP, NADAM, ADAMAX ve ADAGRAD olmak üzere 5 farklı optimizör kullanarak ResNet50, ResNet101, InceptionV3, DenseNet121, DenseNet201, MobileNetV3 ve NasNet CNN tabanlı derin öğrenme yöntemleri ile bitki görüntülerinden hastalık sınıflandırması yapmıştır. Ayrıca CNN modellerinin tümünün sonucunu gözetmek için modellerin sınıflandırma katmanını çıkarılarak fully connected katmanlarından gelen sonuçların birleştirilerek öğrenim durumunu gerçekleştiren yeni bir derin ensemble sinir ağı modeli geliştirilmiştir.

Farklı veri setlerinin de kullanılacağı gibi PlantVillage veri setindeki hastalık sınıflarının azaltılması ve farklı veri setleri ile çalışma durumları da literatürde incelenmiştir. Wang ve ark. (2017), PlantVillage veri setindeki sadece elma görüntülerini kullanarak elma görüntülerindeki hastalıkları CNN tabanlı derin öğrenme yöntemleri olan VGG16, VGG19, InceptionV3 ve ResNet50 modelleri ile sınıflandırmıştır ve model başarımlarını karşılaştırmıştır. Priyadharshini ve ark. (2019), PlantVillage veri setindeki mısır görüntülerini kullanarak mısır görüntülerindeki 4 hastalığın, geliştirdikleri LeNet derin öğrenme yöntemi ile %97,89 doğruluk oranı ile sınıflandırmışlardır. Chohan ve ark.

(2020), 5 evriřim katmanlı basit bir CNN modeli kullanarak bitki yapraklarından hastalık sınıflandırması yapmıştır. Geliřtirdikleri modeli, drone veya telefonda elde edilen 100 adet gerek dnya verisinde test etmiřlerdir. Elde edilen veriler modelin rettięi sınıflarda yer almadıęı iin sadece gerek veriler zerinde saęlıklı ve saęlıksız sınıflandırılması yapılmıştır. 100 grntnn 96'sı saęlıklı/saęlıksız olarak doęru řekilde sınıflandırılmıştır. Ahmed ve ark. (2021), Kaggle, PlantVillage ve Google Web Scraper olmak zere 3 farklı veri kaynaęından topladıkları veriler ile 3 evriřim katmanlı bir CNN modeli geliřtirmiřtir. Bitki hastalık sınıflandırılması iin geliřtirilen derin ęrenme modelini Android tabanlı bir mobil uygulama zerinden de alıřacak řekilde deploy etmiřlerdir. Russel ve ark. (2022), PlantVillage veri seti ve MepcoTrophicLeaf veri seti olmak zere iki veri seti zerinde alıřma gerekleřtirmiřtir. Her iki veri seti iin de altı kanallı paralel ęrenebilen CNN tabanlı bir derin ęrenme yntemi kullanarak ilk olarak bitki yapraęının trnn sınıflandırılmasını ikinci olarak da bitki hastalık sınıflandırılmasını yapmışlardır. Ayrıca alıřmalarından elde ettikleri sonuları literatrde yapılmıř benzer alıřmalar ile kıyaslamışlardır. Borhani ve ark. (2022), kk bir veri seti olan Wheat Rust Classification, orta dzey bir veri seti olan Rice Leaf Disease ve byk bir veri seti hacmine sahip PlantVillage veri setleri zerinde alıřmıştır. CNN modellerinin temelini oluřturan evriřim katmanları ile Transformer modellerinin temelini oluřturan attention katmanlarını birleřtirerek yeni bir model ile bitki hastalık sınıflandırılması yapılmıştır. Geleneksel CNN tabanlı model ile geliřtirilmiř olan VİT model bařarımı  veri setinde kıyaslanmıştır. Geetharamani ve ark. (2019), image filling, gamma correction, noise injection, principal component analysis colour augmentation, rotation ve scaling veri artırma yntemleri kullanılarak artırılan veri ile 9 katmanlı bir CNN derin ęrenme modeli geliřtirmiřtir. Bylelikle PlantVillage veri setine uygulanacak veri artırımı ile model bařarım deęerlendirilmesi yapılmıştır.

PlantVillage veri seti ile eęitilen derin ęrenme yntemlerinin gerek hayatta elde edilen grntler zerinde deęerlendirilmesi zerine yapılan alıřmalara da literatrde rastlanmaktadır. Chen ve ark. (2020), bitki grntlerindeki hastalıkların sınıflandırılması iin PlantVillage veri seti ve gerek hayatı yansıtması aısından indeki Fujian Institute of Subtropical Botany den alınan 1000 adet mısır ve pirin grnt veri setini kullanmıştır. ImageNet veri setinde nceden eęitilmiř modellerden transfer learning yapılan VGG19 ve Inception modeli ile cascade bir model yaklařımı sunulmuřtur. Her iki veri setinde de model sonu karřılařtırılması yapılmıştır. Hassan ve ark. (2021), bitki grntlerinden hastalık sınıflandırılması iin InceptionV3, InceptionResNetV2,

MobileNetV2 ve EfficientNet-B0 olmak üzere 4 farklı CNN tabanlı derin öğrenme yöntemi karşılaştırarak gerçek hayatta zamansal açıdan hangisinin etkili olabileceği üzerinde durmuştur. Moupojou ve ark. (2023), tarım sektöründe önemli bir sorun teşkil eden bitki hastalıklarının tespiti ve sınıflandırılmasında derin öğrenme modellerinin kullanımını ele almaktadır. Bu alanda yapılan araştırmalar, hastalıklı bitkilerin erken teşhis edilerek zararlı etkilerinin en aza indirilmesi amacıyla çeşitli modeller geliştirmiştir. Ancak, bu modellerin büyük çoğunluğu, laboratuvar koşullarında çekilmiş ve basit arka planlara sahip görüntülerle eğitilmiştir. Bu durum, modellerin gerçek tarım alanlarında kullanılan karmaşık ve değişken ortamlarda uygulandığında performans düşüşüne yol açmaktadır. Bu makale, bu sorunu çözmek amacıyla FieldPlant adlı yeni bir veri setini tanıtmaktadır. FieldPlant, Kamerun'dan toplanan 5.170 bitki hastalığı görüntüsünden oluşmakta ve 27 farklı hastalık sınıfında 8.629 bireysel yaprak etiketlemesi içermektedir. FieldPlant veri seti, gerçek dünya koşullarında çekilmiş olması ve daha çeşitli hastalık ve bitki türleri içermesi nedeniyle mevcut veri setlerinden daha üstün performans göstermektedir. FieldPlant veri setinin derin öğrenme modelleri için hem eğitim hem de test veri seti olarak kullanılabileceğini ve bu modellerin tarım alanlarında bitki hastalıklarının tespitinde daha doğru ve etkili sonuçlar sağlayabileceğini vurgulamaktadır. FieldPlant'ın kullanımı, tarım sektöründe hastalıkların erken teşhis edilmesi ve zararlı etkilerinin azaltılması yoluyla ürün verimini artırabilir ve ekonomik kayıpları en aza indirebilir. FieldPlant veri setinin bitki patologlarının gözetimi altında etiketlenmiş olması nedeniyle diğer veri setlerine kıyasla daha yüksek doğruluk oranına sahip olduğunu belirtmektedir. Bu durum, FieldPlant'ın derin öğrenme modellerinin eğitimi için daha güvenilir bir kaynak olduğunu göstermektedir. FieldPlant veri setinin kullanılabilir hale gelmesi, bitki hastalıklarının tespiti ve sınıflandırılması alanında önemli bir ilerleme olarak değerlendirilmektedir.

3. MATERYAL VE YÖNTEM

Bu çalışmada, bitki hastalıklarının sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğini değerlendirmek amacıyla çeşitli modeller kullanılmış ve bu modellerin gerçek dünya performansları test edilmiştir. Çalışmanın ana materyalini, bitki hastalıklarının görüntülerini içeren PlantVillage veri seti oluşturmaktadır. Bu veri seti, modellerin eğitiminde kullanılmıştır. Modellerin eğitim sürecinin tamamlanmasının ardından, eğitilen modellerin gerçek dünya performanslarını değerlendirmek üzere Plant Pathology 2020 ve 2021 veri setleri kullanılmıştır (Plant Pathology, 2020; Plant Pathology, 2021). Bu bölümde, çalışmada kullanılan veri setlerinin özellikleri, veri ön işleme adımları, derin öğrenme modellerinin mimarileri, eğitim ve test süreçleri ile performans değerlendirme kriterleri ayrıntılı bir şekilde ele alınmıştır.

3.1. Veri Setleri

Bu çalışmada, bitki hastalıklarının sınıflandırılması amacıyla üç temel veri seti kullanılmıştır: PlantVillage veri seti ve Plant Pathology 2020 ile 2021 veri setleri. PlantVillage veri seti, bitki hastalıklarının tanınması ve sınıflandırılması için model eğitiminde kullanılmıştır. Bu veri seti, farklı bitki türlerine ve çeşitli hastalıklara ait laboratuvar ortamından elde edilen geniş bir görüntü koleksiyonunu içermektedir. Diğer yandan, Plant Pathology 2020 ve 2021 veri setleri, modellerin gerçek dünya performansını değerlendirmek amacıyla kullanılmıştır. Bu veri setleri, gerçek saha koşullarında elde edilmiş görüntülerden oluşmaktadır ve modellerin genelleme yeteneklerini test etmek için önemli bir kaynak sağlamaktadır. Plant Pathology veri setleri, hastalık tespitinde modellerin doğruluğunu ve güvenilirliğini ölçmek için kritik bir rol oynamaktadır. Aşağıda, her bir veri setinin özellikleri ve bu çalışmada nasıl kullanıldıkları detaylı bir şekilde açıklanmaktadır.

3.1.1. PlantVillage

PlantVillage veri seti, 14 bitki için 26 hastalıklı bitki sınıfı, 12 sağlıklı bitki sınıfı ve 1 bitki görüntülerinden oluşmayan arka plan sınıfı olmak üzere toplam 39 sınıfı içeren toplam 61486 adet görüntüden oluşmaktadır. Veri setine ait istatistiki bilgiler Çizelge 1'de verilmiştir. Veri setindeki görüntüler, görüntü doldurma, gamma düzeltmesi, gürültü enjeksiyonu, renk artırımı, döndürme ve ölçeklendirme veri artırımı yöntemleri ile

çoğaltılmıştır (Geetharamani ve ark., 2019). Veri setindeki görüntüler laboratuvar ortamından elde edilen örneklerden oluşmaktadır. Her bir sınıfa ait örnek görüntüler Şekil 1’de verilmiştir.

Çizelge 1. PlantVillage veri seti sınıf dağılımları

Sınıf Adı	Görüntü Sayısı
Apple with scab	1000
Apple with black rot	1000
Apple with cedar apple rust	1000
Healthy apple	1645
Blueberry with healthy	1502
Cherry with powdery mildew	1052
Cherry with healthy	1000
Corn with grey leaf spot	1000
Corn with common rust	1192
Corn with northern leaf blight	1000
Healthy corn	1162
Grape with black rot	1180
Grape with black measles	1383
Grape with leaf blight	1076
Healthy grape	1000
Orange with Huanglongbing	5507
Peach with bacterial spot	2297
Healthy peach	1000
Pepper with bacterial spot	1000
Healthy pepper	1478
Potato with early blight	1000
Healthy potato	1000
Potato with late blight	1000
Healthy raspberry	1000
Healthy soybean	5090
Squash with powdery mildew	1835
Healthy strawberry	1000
Strawberry with leaf scorch	1109
Tomato with bacterial spot	2127
Tomato with early blight	1000
Healthy tomato	1591
Tomato with late blight	1909
Tomato with leaf mold	1000
Tomato with septoria leaf spot	1771
Tomato with two spotted spider mite	1676
Tomato with target spot	1404
Tomato with mosaic virus	1000
Tomato with yellow leaf curl virus	5357
Background without leaf	1143
Toplam	61486



Şekil 1. PlantVillage veri setindeki her bir sınıftan örnek görüntüler

3.1.2. Plant Pathology 2020 ve Plant Pathology 2021

Plant Pathology 2020 ve Plant Pathology 2021 veri setleri, gerçek hayattaki elma yaprağı görüntüleri kullanılarak hastalık sınıflandırılması yapılmasına yönelik 2020 ve 2021 yıllarında Kaggle platformunda yarışma için açık kaynak olarak paylaşılmıştır. Plant Pathology 2020 veri seti 4 hastalık sınıfı içeren 1821 elma yaprağı görüntülerinden oluşmakta iken Plant Pathology 2021 veri seti ise 12 hastalık sınıfını içeren 18632 elma yaprağı görüntülerinden oluşmaktadır. Veri setlerine ait sınıf dağılımları ve örnek görüntüler sırasıyla Çizelge 2-3 ve Şekil 2-3'te verilmiştir. Plant Pathology 2020 veri setindeki "Multiple Diseases" sınıfı, birden fazla hastalığı kapsadığı için test

süreçlerinden çıkarılmıştır. Ayrıca, Plant Pathology 2021 veri setinde bulunan 12 sınıf yerine, test süreçlerinde "Scab", "Frog Eye Leaf Spot", "Rust" ve "Healthy" olmak üzere sadece dört sınıf kullanılmıştır. Bu düzenlemeler, PlantVillage veri setindeki hastalık sınıfları ile uyumlu testler yapabilmek amacıyla gerçekleştirilmiştir.

Çizelge 2. Plant Pathology 2020 veri seti sınıf dağılımları

Sınıf Adı	Görüntü Sayısı
Scab	592
Multiple Diseases	91
Rust	622
Healthy	516
Toplam	1821

Çizelge 3. Plant Pathology 2021 veri seti sınıf dağılımları

Sınıf Adı	Görüntü Sayısı
Scab	4826
Frog eye leaf spot	3181
Rust	1860
Healthy	4624
Complex	1602
Powdery mildew	1184
Scab frog eye leaf spot	686
Scab frog eye leaf spot complex	200
Frog eye leaf spot complex	165
Rust frog eye leaf spot	120
Rust complex	97
Powdery mildew complex	87
Toplam	18632



Şekil 2. Plant Pathology 2020 veri seti örnek görüntüler (Plant Pathology, 2020)



Şekil 3. Plant Pathology 2021 veri seti örnek görüntüler (Plant Pathology, 2021)

3.2. Veri Önışleme

Veri önışleme, bitki hastalıklarının derin öğrenme ile sınıflandırılması sürecinde kritik bir adımdır. Bu süreç, ham verilerin analiz için uygun hale getirilmesini ve modelin performansını maksimize etmeyi amaçlar. Doğru ve etkili veri önışleme; modelin doğruluğunu, genel performansını ve genelleme yeteneğini önemli ölçüde artırabilir. Özellikle derin öğrenme modellerinde, kaliteli ve doğru ön işlenmiş veri setleri, modelin eğitim sürecini hızlandırır ve modelin daha doğru tahminler yapmasını sağlar. Bu süreçte, verilerin dikkatlice analiz edilmesi, temizlenmesi ve uygun formatlarda düzenlenmesi gerekmektedir. Bu bölümde, veri keşfi, veri normalizasyonu, veri artırma ve veri ayrıştırma işlemleri ele alınmıştır.

3.2.1. Veri Keşfi

Veri keşfi, verilerin yapısını, özelliklerini ve potansiyel sorunlarını anlamak için yapılan ilk adımdır. Bu süreçte aşağıdaki adımlar izlenir (Steingrimsson ve ark., 2021):

- **Veri Toplama:** Bitki hastalıklarının görüntüleri çeşitli kaynaklardan toplanır. Bu kaynaklar tarım araştırma enstitüleri, tarım üniversiteleri, açık veri tabanları ve çiftçiler olabilir.
- **Veri Analizi:** Toplanan veriler incelenir ve veri setinin büyüklüğü, sınıflar arasındaki dağılım, görüntü kalitesi ve eksik veri durumu analiz edilir.
- **Veri Görselleştirme:** Veri dağılımını ve olası dengesizlikleri görmek için çeşitli görselleştirme teknikleri kullanılır. Örneğin, her bir hastalık sınıfına ait görüntülerin sayısını gösteren bar grafikleri ve görüntü örnekleri incelenir.
- **Veri Temizleme:** Eksik, bozuk veya yanıltıcı veriler tespit edilir ve veri setinden çıkarılır veya uygun şekilde düzeltilir.

3.2.2. Veri Normalizasyonu

Veri normalizasyonu, veri setindeki görüntülerin belirli bir standartta olmasını sağlamak için yapılan işlemlerdir. Bu adımlar, modelin daha hızlı ve doğru öğrenmesini sağlar (Singh ve ark., 2020; Talebi ve ark., 2021):

- **Görüntü Boyutlandırma:** Tüm görüntüler aynı boyuta (örneğin 224x224 piksel) getirilir. Bu, modelin her bir görüntüyü aynı şekilde işlemesini sağlar.
- **Piksel Değerlerinin Ölçeklenmesi:** Görüntü piksel değerleri genellikle 0-255 arasında değişir. Bu değerler, modelin daha etkili öğrenebilmesi için 0-1 aralığına ölçeklenir.
- **Renk Kanalları Normalizasyonu:** Görüntülerin RGB (kırmızı, yeşil, mavi) kanalları ayrı ayrı normalleştirilir. Her kanalın ortalama ve standart sapması hesaplanarak, bu değerler kullanılarak normalizasyon yapılır.

3.2.3. Veri Artırma

Veri artırma, mevcut veri setini çeşitli tekniklerle genişletme sürecidir. Bu, modelin daha genelleştirilebilir ve sağlam olmasını sağlar (Mikołajczyk ve ark., 2018; Shorten ve ark., 2019; Chlap ve ark., 2021):

- **Dönme (Rotation):** Görüntüler belirli açılarla döndürülerek yeni görüntüler elde edilir.
- **Kesme (Cropping):** Görüntülerin rastgele bölgeleri kesilerek yeni görüntüler oluşturulur.
- **Yansıma (Flipping):** Görüntüler yatay veya dikey olarak yansıtılır.
- **Parlaklık ve Kontrast Ayarı:** Görüntülerin parlaklık ve kontrastı rastgele değiştirilir.
- **Gürültü Eklenmesi:** Görüntülere rastgele gürültü eklenir.
- **Renk Değişiklikleri:** RGB kanallarının değerleri rastgele değiştirilir.

Bu teknikler, modelin farklı çevresel koşullarda bile hastalıkları doğru bir şekilde tanımlamasına yardımcı olur.

3.2.4. Veri Ayırıştırma

Veri ayırıştırma, veri setinin eğitim, doğrulama ve test setlerine bölünmesi işlemidir. Bu, modelin performansının doğru bir şekilde değerlendirilmesini

sağlamaktadır (Eelbode ve ark., 2021; Ueda ve ark., 2021; Yoon ve ark., 2021). Literatürde veri ayrıştırma için sıklıkla rastgele bölme yöntemi kullanılmaktadır. Bu yöntem ile veri ayrıştırma işlemi rastgele yapılır, ancak her sınıfın temsil edilmesine dikkat edilir (Kahlout ve ark., 2021). Rastgele bölme yöntemi şu şekilde açıklanabilir:

- Eğitim Seti: Modelin öğrenmesi için kullanılan veri setidir. Genellikle veri setinin %70-80'i bu kategoriye ayrılır.
- Doğrulama Seti: Modelin hiperparametre ayarları ve erken durdurma gibi işlemler için kullanılan veri setidir. Genellikle veri setinin %10-15'i bu kategoriye ayrılır.
- Test Seti: Modelin genel performansını değerlendirmek için kullanılan veri setidir. Genellikle veri setinin %10-15'i bu kategoriye ayrılır.

Rastgele bölme yöntemi, veri setini eğitim, doğrulama ve test setlerini rastgele ayırarak hızlı ve kolay bir veri ayrıştırma yöntemi sunar. Ancak bu yöntem, bazı önemli eksiklikler ve sınırlamalar taşır. Öncelikle, rastgele bölme, veriyi yalnızca bir kez böldüğü için elde edilen performans ölçütleri, veri setinin belirli bir bölünmesine bağlı kalır. Bu durum, modelin genelleme yeteneğini tam olarak yansıtmayabilir ve sonuçların tesadüfi dalgalanmalardan etkilenmesine yol açabilir. Ayrıca, özellikle küçük veri setlerinde, rastgele bölme yöntemi eğitim ve test setlerinin dengesiz veya temsili olmamasına neden olabilir, bu da modelin performansını yanıltıcı bir şekilde yüksek veya düşük gösterebilir. Rastgele bölme yönteminin bir diğer önemli eksikliği, veri setindeki her bir gözlemin eğitim ve test setinde sadece bir kez yer almasıdır. Bu, özellikle veri setinde sınırlı sayıda örnek olduğunda, modelin belirli veri örneklerini hiç görmemesi veya bazı örneklerin test setinde hiç yer almaması riskini doğurur. Bu durum, modelin gerçek dünya verilerine karşı dayanıklılığını ve genelleme yeteneğini azaltabilir. Bu nedenlerle, daha güvenilir ve genelleştirilebilir bir model değerlendirmesi için K-fold çapraz doğrulama yöntemi tercih edilir (Xiong ve ark., 2020).

Şekil 4'te gösterildiği üzere, K-fold çapraz doğrulama, veri setini K eşit parçaya böler. Bu parçaların her biri, bir kez test seti olarak kullanılırken, kalan K-1 parça eğitim seti olarak kullanılır. Bu süreç K kez tekrarlanır ve her bir parça için modelin performansı kaydedilir. Sonuç olarak, modelin genel performansı, tüm parçalardaki (fold) performansın ortalaması alınarak hesaplanır. Bu yöntem, rastgele bölme yöntemine kıyasla daha güvenilir ve genelleştirilebilir bir performans değerlendirmesi sağlar (Gorriz ve ark., 2024).

K-fold çapraz doğrulamanın başlıca avantajları arasında, modelin farklı veri setleri üzerinde nasıl performans gösterdiğini kapsamlı bir şekilde değerlendirme imkanı ve veri setinin tamamının hem eğitim hem de test amacıyla kullanılması yer alır. Bu, modelin genelleme yeteneğini artırır ve overfitting riskini azaltır. Özellikle küçük veri setlerinde, K-fold çapraz doğrulama, modelin performansını daha doğru bir şekilde değerlendirmek için vazgeçilmez bir yöntemdir. Bu nedenle, rastgele bölme yöntemi yerine K-fold çapraz doğrulama kullanmak, modelin güvenilirliğini ve doğruluğunu artırmada önemli bir rol oynar.



Şekil 4. K-Fold Çapraz Doğrulama


3.3. Derin Öğrenme Modelleri

Bitki yaprak görüntülerinden hastalık sınıflandırılması için literatürde evrişimli sinir ağları ve transfer tabanlı derin öğrenme yöntemlerinin sıklıkla kullanıldığı görülmektedir. Evrişimli sinir ağı (Convolutional neural network) 1980'lerde Yen leCun tarafından tanıtılmıştır (LeCun ve ark., 1989). Ancak popülerliğini koruyamamıştır. 2012 yılında AlexNet derin öğrenme yöntemi ile ImageNet yarışmasını kazanınca CNN'ler daha popüler hale gelmiştir (Borhani ve ark., 2022). Bugünlerde, görüntü sınıflandırma, nesne tespiti, nesne takibi, doğal dil işleme, stil transferi gibi problemlerin çözümü evrişimli sinir ağı tabanlıdır. Geleneksel makine öğrenimi yaklaşımlardan farklı olarak, CNN'ler, belirli özellikleri manuel olarak çıkarmak yerine, filtreleri giriş görüntüsünün üzerine kaydırarak çıkarılan öznitelikler ile doğrudan orijinal görüntüden öğrenebilmektedir.

Bu çalışmada kullanılan derin öğrenme yöntemlerinin veya tipik bir CNN modelinin temel mimarisi, Şekil 5'ten görüleceği üzere evrişim katmanları (convolution), havuzlama katmanları (pooling) ve tam bağlantı katmanlarından (fully connected)

oluşmaktadır. Bitki yaprak görüntülerinden sınıflandırma yapmak için CNN modeline girdi olarak verilen bir görüntü;

- Convolution katmanında; geçirilerek önemli öznitelikler (features) çıkarılır.
- Pooling katmanında; hesaplama karmaşıklığını azaltmak ve overfitting riskini engellemek amacıyla boyut indirgeme işlemi yapılır.
- Fully connected katmanında; çıkarılan öznitelikler kullanılarak sınıf tahmini yapılır. Sigmoid, softmax en sık kullanılan fonksiyonlardır.




Şekil 5. Tipik bir evrişimli sinir ağı yapısı (Too ve ark., 2019)

“Attention Is All You Need” başlıklı makale (Vaswani ve ark., 2017) ile tanıtılan Transformer mimarisi, öncelikle doğal dil işleme (NLP) alanındaki teknolojiler için geliştirilmiştir. Bu mimari, günümüzde ChatGPT gibi gelişmiş dil modellerinin temelini oluşturacak kadar büyük bir başarı elde etmiştir. Transformer'ların sağladığı bu başarı, onların sadece doğal dil işleme alanında değil, aynı zamanda görüntü işleme gibi diğer alanlarda da kullanılmasına yol açmıştır. Görüntü işleme alanında, Transformer tabanlı yaklaşımlar Visual Transformers olarak adlandırılmış ve bu yaklaşımlar, CNN modellerine alternatif olarak geliştirilmiştir. Visual Transformers'ın en belirgin farkı, CNN modellerinin aksine, görüntüyü parçalara ayırarak işlem yapmalarıdır. CNN modelleri, görüntünün tamamını işleme tabi tutarken, Visual Transformers görüntüyü daha küçük parçalara böler ve bu parçalar üzerinde işlem yapar. Bu, Transformer tabanlı modellerin daha esnek ve güçlü olmasını sağlar (Thakur ve ark., 2021; Borhani ve ark., 2022).

Şekil 6'dan görüleceği üzere temel bir visual transformers modeli 4 ana bileşenden oluşmaktadır (Thakur ve ark., 2022; Thakur ve ark., 2023).

- Patch + Position Embedding mimarisi; giriş görüntüsü küçük parçalara (patch'lere) bölünür. Örneğin, 256x256 piksel bir görüntü, 16x16 piksel boyutunda parçalara ayrılabilir. Bu şekilde, görüntü, bir dizi küçük parça haline getirilir. Her bir parçanın hangi sırayla geldiğini belirlemek için bir konum numarası eklenir. Bu, modelin parçaların konumlarını ve sırasını öğrenmesine yardımcı olur.
- Linear projection of flattened patches mimarisi; elde edilen her bir parça düzleştirilir ve belirli bir boyuta sahip bir vektöre dönüştürülür. Bu vektörlere embedding denir. Embeddinglerin kullanımı, görüntüleri doğrudan kullanmak yerine, bu vektörlerin model tarafından öğrenilebilir temsiller olarak işlev görmesini sağlar.
- Transformer Encoder; gelen embedding ve konum bilgilerini attention katmanlarından geçirerek anlamlandırır. Attention mekanizması, modelin hangi parçalara odaklanması gerektiğini belirler ve bu sayede daha doğru ve anlamlı sonuçlar elde edilir. Transformer Encoder, birden fazla katmandan oluşur ve her katman, input embedding'lerin daha karmaşık ve soyut temsillerini öğrenir.
- MLP head mimarisi; Transformer yapısının çıktı katmanıdır. Burada, modelin öğrendiği özellikler bir sınıf çıktısına dönüştürülür. Örneğin, bir görüntü sınıflandırma görevi için, MLP Head modeli, her bir parçanın hangi sınıfa ait olduğunu belirlemek için kullanılır.




Şekil 6. Visual Transformer yapısı (Dosovitskiy ve ark., 2020)


Saleem ve ark. (2020), Atila ve ark. (2021), Wang ve ark. (2017) ve Chen ve ark. (2020) bitki hastalıklarının tespiti için CNN kullanırken, Borhani ve ark. (2022) transformers tabanlı derin öğrenme yöntemleri kullanmıştır. Bu tez çalışmasında, literatürde sıklıkla kullanılan ResNet152, VGG16, EfficientNet-B0, EfficientNet-B1, DenseNet201, GoogLeNet ve Vision Transformers Large 32 (ViT Large 32) gibi hem CNN hem de transformers tabanlı derin öğrenme yöntemleri hazırlanan PlantVillage veri seti üzerinde eğitilerek bitki hastalıklarının tespitinde kullanılmıştır. Bu modellerin seçilme nedenleri aşağıda detaylı bir şekilde açıklanmıştır:

3.3.1. ResNet152

ResNet (Residual Networks), derin öğrenme modellerinde sıklıkla karşılaşılan vanishing gradient problemine yenilikçi çözümler sunarak daha derin ağların etkili bir şekilde eğitilmesini mümkün kılan bir mimaridir. Vanishing gradient problemi, derin ağlarda gradientlerin geri yayılım sırasında katmanlar arasında küçülmesiyle ortaya çıkar, bu da modelin eğitilmesini zorlaştırır. Bu model, Şekil 7’de gösterilen residual bloklar kullanarak bu sorunu aşar. Her residual blok, iki veya daha fazla katmandan oluşur ve bu katmanların çıkışlarına orijinal giriş sinyalinin eklenmesiyle çalışır. Bu, gradientlerin kaybolmasını engeller ve daha derin ağların eğitilmesini sağlar. Şekil 8’de iç mimarisi gösterilen ResNet152 modeli, 152 katmandan oluşan derin bir modeldir. Modelin temelini oluşturan residual bloklar, her bir katmandan gelen çıktının doğrudan sonuca eklenmesini sağlar. Bu ekleme işlemi, modelin her katmanda gradient bilgisini koruyarak öğrenmeyi sürdürebilmesine imkan tanır. Teknik olarak, her residual blok iki ana bileşenden oluşur: bir doğrusal dönüşüm katmanı ve bir identity mapping katmanı. Doğrusal dönüşüm katmanları, girdiyi farklı boyutlara dönüştürürken, identity mapping katmanı girdi sinyalini olduğu gibi çıkışa ekler. Bu yapı, ağın çok derin olmasına rağmen verimli bir şekilde öğrenmesini sağlar (He ve ark., 2016).



Şekil 7. Residual Block (He ve ark., 2016)




Şekil 8. ResNet152 mimarisi (Shih ve ark., 2020)

Bu çalışmada, ResNet152'nin bitki hastalıklarının tespiti için kullanılması, modelin derin katmanlarının bitki yapraklarındaki hastalık belirtilerini yüksek doğrulukla tespit etme kapasitesi göz önünde bulundurularak tercih edilmiştir. Derin yapısı, modelin karmaşık ve ince özellikleri öğrenmesini mümkün kılar. Bu özellik, bitki hastalıklarının tespitinde kritik öneme sahiptir. Bitki yapraklarındaki hastalık belirtileri, renk değişiklikleri, dokusal farklılıklar ve lekeler gibi ince detayları içerebilir. ResNet152'nin derin katmanları ve residual blok yapısı, bu tür ince detayları yakalamada etkili olmasını sağlar.

3.3.2. VGG16

VGG16'nın mimarisi, Şekil 9'da gösterildiği üzere, derin öğrenme modellerinin yapı taşları olan evrişimsel katmanlar, max-pooling katmanları ve tam bağlı katmanlardan oluşmaktadır. Modelin adındaki '16' rakamı, toplamda 16 ağırlık katmanı (13 evrişimsel katman ve 3 tam bağlı katman) olduğunu belirtmektedir. VGG16'nın en belirgin özelliklerinden biri, 3x3 boyutundaki evrişim çekirdeklerinin (filter) kullanılmasıdır. Bu küçük filtreler, modelin daha karmaşık özellikleri yakalamasına olanak tanımaktadır. Evrişimsel katmanlardan sonra gelen max-pooling katmanları, boyut azaltma işlemini

gerçekleştirerek modelin hesaplama yükünü hafifletir ve overfitting (aşırı uyum) riskini azaltır. Modelin tüm katmanlarında aynı evrişim çekirdekleri ve pooling stratejileri kullanılır, bu da mimarinin tutarlı ve anlaşılır olmasını sağlar. VGG16, evrişimsel katmanlarda ReLU aktivasyon fonksiyonunu kullanır, bu da modelin doğrusal olmayan özellikleri öğrenmesini kolaylaştırır. Ayrıca, tam bağlı katmanlarda Dropout tekniği kullanılarak overfitting'in önüne geçilir. VGG16'nın PlantVillage veri seti üzerinde kullanılması, modelin homojen yapısı ve yüksek performansı göz önünde bulundurularak tercih edilmiştir. Modelin derin katmanları, bitki yapraklarındaki hastalık belirtilerini yüksek doğrulukla tespit etmeye olanak tanır. VGG16'nın basit ama etkili yapısı, bitki hastalıklarının belirlenmesinde sağlam ve güvenilir bir model olarak öne çıkmasını sağlar (Simonyan ve ark., 2014).




Şekil 9. VGG16 mimarisi (Mridha ve ark., 2021)

3.3.3. EfficientNet

EfficientNet modelleri, derin öğrenme alanında model boyutu ve performans arasındaki dengeyi optimize ederek daha verimli bir öğrenme süreci sunan ileri düzey evrişimli sinir ağı mimarileridir. Bu modeller, ağ ölçeklendirme problemini çözmek için "Compound Scaling" adı verilen bir teknik kullanarak tasarlanmıştır. Compound Scaling, ağın derinliğini, genişliğini ve çözünürlüğünü dengeli bir şekilde ölçeklendirerek daha küçük modellerin bile yüksek doğruluk oranlarına ulaşmasını sağlamaktadır. EfficientNet-B0 ve EfficientNet-B1 modellerinin bu projede tercih edilmesinin ana sebepleri, verimlilik ve performans açısından optimize edilmiş olmalarıdır. Şekil 10'da gösterilen EfficientNet modeli, Mobile Inverted Bottleneck Convolution (MBConv) katmanlarını kullanarak verimliliğini artırır. MBConv katmanları, klasik evrişimsel katmanlardan farklı olarak dar boğaz (bottleneck) yapısını tersine çevirir ve genişletme (expansion) aşamasıyla başlar. MBConv katmanlarının temel yapısı, ilk olarak giriş

özellik haritasını genişletir, ardından derinlik-kısa evrişim (depthwise convolution) uygular ve son olarak da daraltarak (projection) çıkış özellik haritasını üretir. Bu yapı hem hesaplama verimliliğini artırır hem de modelin daha fazla özellik öğrenmesini sağlar. MBConv katmanları, EfficientNet modellerinin hesaplama gereksinimlerini azaltırken yüksek doğruluk oranları elde etmesine olanak tanır (Tan ve ark., 2019).

EfficientNet-B0 ve EfficientNet-B1 modelleri arasındaki temel farklar, parametre sayısı, hesaplama gereksinimleri ve giriş görüntü boyutlarıdır. EfficientNet-B0, 5,3 milyon parametre ve 0,39 milyar FLOPs ile daha az hesaplama kaynağı gerektirirken, EfficientNet-B1, 7,8 milyon parametre ve 0,70 milyar FLOPs ile daha fazla hesaplama gücü gerektirir. EfficientNet-B0, düşük kaynak gereksinimleriyle etkili bir başlangıç noktası sunarken, EfficientNet-B1, daha yüksek doğruluk oranları ve karmaşık veri setleri için daha uygun bir seçenektir. Bu modeller, farklı büyüklükteki veri setlerine uyarlanabilir ve hesaplama kaynaklarını verimli kullanmaları nedeniyle bitki hastalıklarının tespiti gibi spesifik uygulamalarda üstün performans göstermektedir (Nayak ve ark., 2022).




Şekil 10. EfficientNet mimarisi (Gorji ve ark., 2022)

3.3.4. DenseNet201

DenseNet (Densely Connected Convolutional Networks), derin öğrenme modellerinde bilgi akışını ve gradyan yayılımını artırmak amacıyla her katmanı önceki tüm katmanlara bağlayan yenilikçi bir mimaridir. Bu yaklaşım, modelin derinliğine rağmen etkin bir şekilde öğrenme kapasitesini artırır. DenseNet201, 201 katman derinliğine sahip olup, özellikle karmaşık desenlerin ve ince detayların yakalanmasında üstün performans sergiler. Bu özellikleri nedeniyle, bitki hastalıklarının tespitinde

güvenilir sonuçlar elde etmek için kullanılmıştır (Huang ve ark., 2017). Şekil 11’de gösterildiği üzere DenseNet201’in derinliği ve yoğun bağlantı yapısı, modelin karmaşık desenleri ve ince detayları yakalama kapasitesini artırır. Bitki hastalıklarının tespiti gibi uygulamalarda, yapraklardaki hastalık belirtilerini doğru bir şekilde tespit etmek için bu derin ve yoğun yapının sağladığı avantajlar kritik öneme sahiptir. DenseNet201, her katmanının önceki katmanların çıktılarından beslendiği için, daha iyi özellik öğrenimi ve bilgi paylaşımı sağlar (Kumar ve ark., 2023).



Şekil 11. DenseNet mimarisi (Huang ve ark., 2017)


3.3.5. GoogLeNet

GoogLeNet, Inception modüllerinden oluşan bir mimariye sahiptir. Inception modülleri, farklı boyutlarda evrişimler ve pooling işlemleri kullanarak modelin çeşitli ölçeklerdeki özellikleri öğrenmesine olanak tanır. Her Inception modülü, farklı ölçeklerdeki özellikleri paralel olarak öğrenir ve bu özelliklerin birleştirilmiş çıktısını modelin sonraki katmanlarına aktarır. Bu yapı, modelin derinliğini ve genişliğini


arttırırken hesaplama maliyetlerini kontrol altında tutar. Şekil 12’de gösterilen Inception modülleri, üç ana bileşenden oluşur:

- 1x1 Evrişim: Özellik haritasının kanal sayısını azaltarak hesaplama yükünü azaltır ve derinliği artırır.
- 3x3 ve 5x5 Evrişim: Genişletilmiş özellikleri öğrenir ve modelin daha karmaşık desenleri öğrenmesini sağlar.
- Max-Pooling: Uzamsal boyutları azaltarak modelin hesaplama yükünü hafifletir.

Bu modüller, GoogLeNet’in her aşamasında kullanılarak farklı ölçeklerdeki özelliklerin etkili bir şekilde öğrenilmesini sağlar. Şekil 13’te gösterilen GoogLeNet’in mimarisi, her bir Inception modülünün çıktısını birleştirir ve bu şekilde modelin derinliğini artırırken hesaplama verimliliğini korur. (Szegedy ve ark., 2015).



Şekil 12. Inception mimarisi (Szegedy ve ark., 2015)




Şekil 13. GoogLeNet mimarisi (Sundaram ve ark., 2022)

3.3.6. Vision Transformers Large 32

Vision Transformers (ViT), görüntü işleme görevlerinde CNN'lerin ötesine geçme potansiyeline sahip olan transformer tabanlı bir modeldir. ViT, özellikle büyük ölçekli veri setlerinde ve karmaşık görüntü sınıflandırma görevlerinde etkili bir performans sergilemekte, bu sebeple derin öğrenme alanında önemli bir yenilik olarak kabul edilmektedir. ViT'in temel prensibi, görüntüleri küçük parçalara (patch'lere) bölerek bu parçalar üzerinde kendi dikkat (self-attention) mekanizmalarını kullanarak global özellikleri öğrenmektir. Vision Transformers modeli, görüntüleri öncelikle küçük parçalara böler. Bu parçalar, genellikle 16x16 veya 32x32 piksellik karelerdir ve her bir parça, bir vektöre dönüştürülerek transformer yapısına iletilir. Bu işlem, her bir parça için özelliklerin çıkarılmasını sağlar ve bu özellikler, modelin eğitim sürecinde kullanılır.

ViT'in dikkat mekanizması, tüm parçalara aynı anda dikkat ederek, her bir parçanın diğer parçalarla olan ilişkisini anlamaya çalışır. Bu sayede, model global bağlam ve uzun menzilli bağıntıları etkili bir şekilde öğrenebilir. ViT-L32, Vision Transformers ailesinin büyük boyutlu bir versiyonudur. Modelin “Large” (büyük) olarak adlandırılması, daha fazla parametre ve daha derin bir transformer yapısına sahip olduğunu belirtir. ViT-L32, özellikle geniş veri setlerinde ve karmaşık görüntü sınıflandırma görevlerinde yüksek performans göstermektedir. Modelin “32” ibaresi, giriş görüntülerinin 32x32 piksellik parçalara bölündüğünü ifade eder. Bu, daha büyük ölçekli ve detaylı özelliklerin öğrenilmesini sağlar. Şekil 14’te mimarisi gösterilen ViT-L32, büyük boyutlu transformer yapısı sayesinde yüksek kapasiteli ve geniş bir modeldir. Bu, daha karmaşık ve detaylı görüntüleri etkili bir şekilde işleyebilmesini sağlar. ViT-L32'nin dikkat mekanizması, geniş veri setlerinde global bağlamları anlamada ve ince detayları öğrenmede önemli bir avantaj sağlar. Bu özellik, modelin büyük veri setlerinde ve zorlu görüntü sınıflandırma görevlerinde üstün performans göstermesine olanak tanır (Dosovitskiy ve ark., 2020; Tummala ve ark., 2022).










Şekil 14. Vision Transformers mimarisi (Picek ve ark., 2022)

3.4. Açıklanabilirlik

Derin öğrenme mimarileri, görüntüden tahminler yaptığında yalnızca tahmin edilen sınıfı sonuç olarak sunar. Bu da bu yöntemlerin "kara kutu" olarak kabul edilmesine neden olur. Bu sebeple, derin öğrenme modellerinin iç işleyişini anlamak ve açıklamak önemli bir araştırma konusu haline gelmiştir. “Yapay Zekânın Kara Kutusunu Açabilir miyiz?” başlıklı çalışma (Castelvecchi ve ark., 2016), yapay zekâ modellerine yeni bir açıklayıcı bakış açısı kazandırarak bu soruna dikkat çekmiştir. Açıklanabilir


yapay zekâ sistemleri özellikle Sınıf Aktivasyon Haritaları (Class Activation Mapping - CAM) algoritmaları sayesinde, derin öğrenme yöntemlerinin görüntünün hangi bölgelerine odaklanarak tahminler yaptığını göstermektedir. CAM algoritmaları, belirli bir sınıfa ait ağırlıkların ve aktivasyon haritalarının görsel açıklamalarını üreterek modelin karar verme sürecini daha anlaşılır hale getirir (Bhandari ve ark., 2023). Şekil 15'ten görüleceği üzere bu yöntemler, derin öğrenme modellerinin açıklanabilirliğini artırarak, kullanıcıların modellerin nasıl çalıştığını ve neden belirli tahminlerde bulunduğunu daha iyi anlamalarını sağlar.

Category	Leaf	GradCAM
Bacterial spot		
Early blight		
Late blight		
Leaf mold		
Septoria spot		
Spider mite		
Target spot		
Yellow leaf		
Mosaic virus		

Şekil 15. Açıklanabilir Yapay Zekâ (Bhandari ve ark., 2023)

CAM algoritmaları, sınıflandırma modelinin özellik haritalarını görselleştirmek için kullanılan bir tekniktir. Özellikle evrişimli sinir ağları (CNN'ler) gibi derin öğrenme modellerinde hangi görüntü bölgelerinin sınıflandırma kararlarına katkıda bulunduğunu anlamak için kullanılır. Şekil 16'da gösterilen CAM algoritmalarının çalışma yapısı şu şekildedir (Sun ve ark., 2020; Camalan ve ark., 2021; Wei ve ark., 2022; Quach ve ark., 2023).

- **Derin Öğrenme Modelinin Eğitimi:** İlk adım, genellikle bir evrişimli sinir ağı gibi derin öğrenme modelinin eğitilmesidir. Bu model, genellikle bir sınıflandırma görevi için eğitilir ve girdi görüntüleri ile ilgili çeşitli özellikleri tanımlayabilir.
- **Son Evrişim Katmanının Seçilmesi:** CAM gibi tekniklerinde, genellikle modelin son evrişim katmanı kullanılır. Bu katman, girdi görüntüsünü en yakın sınıflara doğru dönüştürmek için özellik haritalarını üretir.
- **Sınıf Belirleme:** İlgilenilen bir sınıf seçilir. Bu sınıf için, modelin çıktı katmanında ilgili nöronun aktivasyon değeri incelenir.
- **Gradient Hesaplama:** Seçilen sınıfın çıktı değeri ile son evrişim katmanındaki her pikselin aktivasyonu arasındaki ilişkiyi belirlemek için geriye doğru yayılım (backpropagation) kullanılır. Bu, her pikselin ilgili sınıfın çıktısını ne kadar etkilediğini ölçen bir gradient haritası üretir.
- **Gradientlerin Ağırlıklandırılması:** Gradient haritasındaki değerler, ilgili piksellerin öneminin belirlenmesi için ağırlıklandırılır. Bu genellikle, gradientlerin pozitif kısımlarının ağırlıklandırılmasıyla yapılır; çünkü pozitif gradientler, ilgili sınıfın çıktısını artırır.
- **Görselleştirme:** Son adımda, ağırlıklandırılmış gradient haritası, orijinal görüntü boyutuna yeniden ölçeklenir ve genellikle görsel olarak uygun bir renk haritası ile birleştirilir. Bu, modelin hangi özelliklere odaklandığını ve sınıflandırma kararını neyin etkilediğini anlamak için bir görsel sağlar.



Şekil 16. CAM Algoritmalarının Çalışma Yapısı (Zhou ve ark., 2016)

Sonuç olarak, CAM algoritmaları, derin öğrenme modellerinin sınıflandırma kararlarını anlamlandırmak ve açıklamak için kritik bir araçtır. Bu algoritmalar, modelin karar alma sürecinde hangi özelliklerin veya bölgelerin belirleyici olduğunu belirleyerek modelin içsel temsillerini daha anlaşılır hale getirir. CAM teknikleri, modelin karmaşık yapısını ve işleyişini görselleştirerek, hangi bölgenin hangi sınıfı tetiklediğini ve modelin neden belirli bir sınıflandırma yaptığını dair içgörü sağlar. Literatürde, GradCAM, GradCAM++, XGradCAM, EigenCAM ve LayerCAM gibi çeşitli CAM algoritmaları geliştirilmiştir. Bu yöntemler, farklı optimizasyon stratejileri ve matematiksel yaklaşımlar kullanarak sınıf aktivasyon haritalarını daha hassas ve detaylı bir şekilde oluşturur. Özellikle tıp, otonom sürüş ve görüntü tanıma gibi alanlarda, bu teknikler model güvenilirliğini ve yorumlanabilirliğini artırarak önemli katkılar sağlamaktadır. Bu bağlamda, CAM algoritmalarının kullanımı, derin öğrenme modellerinin performansını ve güvenilirliğini artırmada hayati bir rol oynamaktadır.

3.4.1. GradCAM

Gradient-weighted Class Activation Mapping (GradCAM) derin öğrenme modellerinin iç işleyişini görselleştirmek için kullanılan bir yöntemdir. GradCAM, modelin belirli bir sınıfa ait olduğunu düşündüğü bölgeleri vurgulayan ısı haritaları oluşturur. Modelin son evrişim katmanının çıktısına gradyanlar uygulayarak çalışır. Bu gradyanlar, belirli bir sınıfın aktivasyonunu artırmak için ne kadar değişiklik gerektiğini gösterir. Elde edilen ısı haritası, modelin dikkate aldığı önemli bölgeleri ortaya çıkarır (Selvaraju ve ark., 2017).

3.4.2. GradCAM++

GradCAM++, GradCAM'in geliştirilmiş bir versiyonudur. GradCAM++ daha ince detaylar ve daha iyi sınıf ayrımı sağlayarak, modelin belirli sınıflar için dikkate aldığı bölgeleri daha hassas bir şekilde vurgular. GradCAM++, orijinal GradCAM'den farklı olarak, yalnızca belirli bir sınıfın değil, birden çok sınıfın katkılarını da dikkate alır. Bu sayede, daha ince detaylar ve daha iyi sınıf ayrımı sağlanır (Chattopadhyay ve ark., 2018).

3.4.3. XGradCAM

XGradCAM, GradCAM'in farklı bir çeşididir ve çeşitli model mimarilerinde daha etkili sonuçlar vermek için optimize edilmiştir. XGradCAM, özellikle derin ve karmaşık ağlarda daha iyi performans gösterir. XGradCAM, farklı ağ katmanlarından gelen bilgileri birleştirerek daha zengin ve ayrıntılı ısı haritaları üretir. Bu, modelin çeşitli seviyelerdeki bilgiye nasıl eriştiğini ve kullandığını gösterir (Fu ve ark., 2020).

3.4.4. EigenCAM

EigenCAM, Temel Bileşen Analizi (Principal Component Analysis - PCA) kullanarak modelin dikkate aldığı ana özellikleri çıkarır. Bu yöntem, modelin dikkatini çeken özelliklerin daha soyut ve genel temsillerini sağlar. EigenCAM, evrimsel katmanların çıktılarını temel bileşen analizi ile analiz eder ve en önemli bileşenleri belirler. Bu bileşenler, modelin dikkate aldığı ana özellikleri temsil eder (Muhammad ve ark., 2020).

3.4.5. LayerCAM

LayerCAM, modelin farklı katmanlarındaki aktivasyonları görselleştirerek modelin hangi katmanlarda hangi bilgileri kullandığını gösterir. Bu, modelin karar verme sürecini daha detaylı bir şekilde anlamamıza yardımcı olur. LayerCAM, her bir katmanın aktivasyon haritalarını analiz eder ve bu haritaları belirli bir sınıfa ait ısı haritaları oluşturmak için kullanır. Bu, modelin hangi katmanlarda hangi özelliklere odaklandığını gösterir (Jiang ve ark., 2021).

3.5. Değerlendirme Metrikleri

Makine öğrenimi ve derin öğrenme modellerinin performansını doğru ve kapsamlı bir şekilde değerlendirebilmek için çeşitli metrikler kullanılır. Bu metrikler, modellerin doğruluğunu, hassasiyetini, duyarlılığını ve genel performansını anlamamıza yardımcı olur. Model performansının objektif bir şekilde ölçülmesi, farklı modellerin karşılaştırılması ve modelin gerçek dünya uygulamalarındaki etkinliğinin değerlendirilmesi için bu metrikler kritik öneme sahiptir. Değerlendirme metrikleri, modelin güçlü ve zayıf yönlerini belirleyerek, iyileştirme yapılabilecek alanları tespit etmemizi sağlar. Aşağıda, makine öğrenimi ve derin öğrenme modellerinin performansını değerlendirmek için yaygın olarak kullanılan metrikler detaylı olarak açıklanmıştır (Kilic ve ark., 2023)

3.5.1. Karmaşıklık Matrisi

Karmaşıklık matrisi, sınıflandırma modelinin performansını değerlendirmek için kullanılan bir tablodur. Bu matris, özellikle birden fazla sınıfın olduğu durumlarda modelin her bir sınıfa ne kadar iyi ya da kötü performans gösterdiğini anlamak için çok değerlidir. Modelin her sınıfı nasıl tahmin ettiğini göstererek, gerçek pozitifler (true positive - TP), gerçek negatifler (true negative - TN), yanlış pozitifler (false positive - FP) ve yanlış negatifler (false negative - FN) üzerinde detaylı bir analiz sunmaktadır (Karakoyun, 2024)

- TP (True Positive): Modelin pozitif olarak tahmin ettiği ve gerçekten de pozitif olan örnek sayısı. Örneğin, bir hastalığın varlığını doğru bir şekilde teşhis etmek.
- TN (True Negative): Modelin negatif olarak tahmin ettiği ve gerçekten de negatif olan örnek sayısı. Örneğin, bir hastalığın yokluğunu doğru bir şekilde teşhis etmek.
- FP (False Positive): Modelin pozitif olarak tahmin ettiği ancak gerçekte negatif olan örnek sayısı. Bu durum, yanlış alarm olarak da adlandırılır.
- FN (False Negative): Modelin negatif olarak tahmin ettiği ancak gerçekte pozitif olan örnek sayısı. Bu, kaçırılmış fırsatlar veya teşhisler anlamına gelir.

PlantVillage veri seti üzerinde eğitilen CNN ve Transformers tabanlı derin öğrenme yöntemlerinin karşılaştırılması için karmaşıklık matrisinde yer alan TP, FP, TN, FN değerleri kullanılarak hesaplanan aynı zamanda literatürde de sıklıkla kullanılan

doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall), f1 skor değerlendirme metrikleri olarak kullanılmıştır. PlantVillage veri seti dengesiz sınıfları içermesi sebebiyle en iyi derin öğrenme yöntemi seçimi yapılırken, doğruluk yerine f1 skor metriği temel alınacaktır.

3.5.2. Doğruluk

Doğruluk, modelin doğru sınıflandırdığı örneklerin toplam örnek sayısına oranıdır. Genel performansı ölçmek için yaygın olarak kullanılan bir metriktir. Doğruluk, veri setinin dengeli olduğu durumlarda modelin genel performansını değerlendirmek için uygundur (Hossin ve ark., 2015; Rainio ve ark., 2024).

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

3.5.3. Hassasiyet

Hassasiyet, modelin pozitif olarak sınıflandırdığı örneklerin gerçekten pozitif olma oranıdır. Yanlış pozitiflerin önemli olduğu durumlarda kullanılır (Hossin ve ark., 2015; Rainio ve ark., 2024).

$$\text{Hassasiyet} = \frac{TP}{TP + FP} \quad (2)$$

3.5.4. Duyarlılık

Duyarlılık, gerçek pozitiflerin model tarafından doğru olarak tanımlanma oranıdır. Yanlış negatiflerin önemli olduğu durumlarda kullanılır (Hossin ve ark., 2015; Rainio ve ark., 2024).

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

3.5.5. F1 Skor

F1 skoru, hassasiyet ve duyarlılığın harmonik ortalamasıdır. Veri setinin dengesiz olduğu durumlarda performansı değerlendirmek için kullanılır (Hossin ve ark., 2015; Liu ve ark., 2023).

$$f1 - skor = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

3.6. Donanım

Derin öğrenme modellerinin eğitimi, yüksek işlem gücü gerektiren bir süreçtir. Bu nedenle, bu tez çalışması kapsamında kullanılacak donanım, bu gereksinimleri karşılayacak düzeyde kullanılmıştır. Kullanılan donanım konfigürasyonu şu şekildedir:

- İşlemci (CPU): AMD Ryzen 5 5600. Bu işlemci, 6 çekirdek ve 12 iş parçacığı ile yüksek işlem kapasitesi sağlayarak, büyük veri setlerinin işlenmesi ve karmaşık model yapılarının hızla eğitilmesi için idealdir. Ryzen 5 5600, modern mimarisi sayesinde derin öğrenme algoritmalarının gerektirdiği paralel işleme görevlerini verimli bir şekilde yerine getirebilir.
- Bellek (RAM): 16GB RAM. Derin öğrenme modelleri, eğitim sırasında büyük miktarda veriyi hafızada tutar. 16GB RAM, bu verilerin hızlı bir şekilde işlenmesini ve modelin eğitim süresince veri alışverişinin kesintisiz devam etmesini sağlar, bu da eğitim sürecini hızlandırır ve verimliliği artırır.
- Grafik İşlem Birimi (GPU): ASUS GeForce DUAL RTX 3060 V2 OC 12GB. GPU, derin öğrenme ve yapay zekâ çalışmalarında kritik bir bileşendir. NVIDIA'nın RTX 3060, geniş bellek kapasitesi ve güçlü işlem yetenekleri ile özellikle görüntü işleme ve video analizi gibi görevlerde yüksek performans sunar. CUDA çekirdekleri ve Tensor Cores ile donatılmış bu grafik kartı, paralel işlemleri hızla gerçekleştirerek model eğitim sürelerini önemli ölçüde düşürür.

Python programlama dili ve PyTorch çerçevesi kullanılarak bu donanım üzerinde derin öğrenme yöntemlerinin eğitimleri gerçekleştirilmiştir.

3.7. Yapay Zekâ Süreci

Bu bölümde, bitki hastalıklarının sınıflandırılması amacıyla kullanılan derin öğrenme modellerinin oluşturulması ve değerlendirilmesi süreci adım adım Şekil 17'de açıklanmıştır. Bitki hastalıklarının sınıflandırılması için kullanılan yapay zekâ iş akışı; veri toplama ve hazırlama, model eğitimi, test aşaması, model değerlendirmesi ve açıklanabilir yapay zekâ adımlarından oluşmaktadır.

Öncelikle, PlantVillage, Plant Pathology 2020 ve Plant Pathology 2021 veri setleri internet üzerinden indirilmiştir. PlantVillage veri seti model eğitimde kullanıldığı için 5-fold çapraz doğrulama yöntemi kullanılarak veri ayrıştırma işlemi gerçekleştirilmiştir. ViT Large 32 modeli için 224x224, diğer modeller için ise 256x256 boyutlarında tüm veri setleri yeniden boyutlandırılmıştır. ViT Large 32 modeli, belirli bir giriş boyutunda önceden eğitilmiştir. Bu eğitim sürecinde model, belirli bir giriş boyutuna (224x224 piksel) optimize edildiğinden ötürü veri setlerinin farklı bir boyutta yeniden boyutlandırılması işlemi gerçekleştirilmiştir. Tüm veri setlerine 0-1 aralığında normalizasyon ve Tensor dönüşümü işlemleri uygulanarak veri hazırlama süreci tamamlanmıştır.


Daha sonra, ResNet152, VGG16, EfficientNet B0, EfficientNet B1, DenseNet201, GoogLeNet ve ViT Large 32 gibi derin öğrenme yöntemleri kullanılarak 5-fold çapraz doğrulama yöntemi kullanılarak PlantVillage veri seti üzerinde modeller eğitilmiştir. Ayrıca Plant Pathology 2020 ve 2021 veri setleri eğitim %80 ve test %20 olacak şekilde rastgele bölme yöntemi kullanarak ayrıştırılmış ve gerçek dünya veri setleri üzerinde model eğitimleri yapılmıştır. Bu modeller, başlangıçta ImageNet veri seti üzerinde önceden eğitilmiş olup, transfer öğrenme yöntemi kullanılarak PlantVillage veri seti üzerinde yeniden eğitilmiştir. Transfer öğrenme süreci, modellerin ImageNet üzerindeki öğrenilmiş ağırlıklarının PlantVillage veri seti üzerindeki yeniden eğitimde kullanılması yoluyla gerçekleştirilmiştir.

Model eğitiminin tamamlanmasının ardından test aşamasına geçilmiştir. PlantVillage veri seti üzerinde 5-fold şeklinde eğitilen modeller (5x7 model = 35 model) PlantVillage doğrulama seti, Plant Pathology 2020 ve 2021 veri setleri üzerinde test edilmiştir. Test sürecinde, modellerin performansı çeşitli metriklerle değerlendirilmiştir. Doğruluk (accuracy), modellerin doğru sınıflandırma oranlarını belirlemek için kullanılmıştır. Hassasiyet (precision), modellerin pozitif sınıflandırmalarının doğruluk oranını ölçerken, duyarlılık (recall) modellerin gerçek pozitifleri doğru bir şekilde

tanımlama yeteneğini değerlendirmiştir. Ayrıca, f1 skoru, hassasiyet ve duyarlılığın harmonik ortalamasını alarak modellerin genel performansını tek bir değerle özetlemiştir. Bu değerlendirmeler, her bir veri seti ve model için ayrı ayrı gerçekleştirilmiş ve sonuçlar, modellerin farklı veri setleri üzerindeki performanslarını karşılaştırmak amacıyla analiz edilmiştir. Elde edilen sonuçlar, modellerin sınıflandırma yeteneklerini, güçlü ve zayıf yönlerini belirlemek ve gelecekteki geliştirmeler için yol gösterici olmak amacıyla detaylı bir şekilde incelenmiştir.

Ayrıca, açıklanabilir yapay zekâ yöntemleri kullanılarak, modellerin karar verme süreçlerinin şeffaflığı ve anlaşılabilirliği artırılmıştır. Modellerin karar mekanizmalarını görselleştiren açıklanabilirlik haritaları oluşturulmuş ve bu haritalar üzerinden modellerin hangi özelliklere dayanarak karar verdiği analiz edilmiştir. Bu haritalar, modellerin doğruluk ve güvenilirliğini artırmakla kalmayıp, aynı zamanda tarım uzmanlarının ve çiftçilerin modellerin çıktısını daha iyi anlamalarına ve bu çıktılara güven duymalarına olanak sağlamaktadır.

Son olarak, elde edilen bulguların genel değerlendirilmesi yapılmış ve tarım sektörü üzerindeki potansiyel etkileri tartışılmıştır. Bu iş akışı, derin öğrenme modellerinin laboratuvar ve gerçek dünya koşullarındaki performanslarını karşılaştırmak ve değerlendirmek amacıyla oluşturulmuştur.



Şekil 17. Yapay Zekâ Süreci (PP = Plant Pathology)

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, derin öğrenme yöntemleri kullanılarak gerçekleştirilen bitki hastalıklarının sınıflandırılması çalışmalarının bulguları ve bu bulguların kapsamlı bir şekilde tartışılması sunulmuştur. Çalışmanın ilk aşamasında, PlantVillage veri seti kullanılarak eğitilen derin öğrenme modellerinin performans sonuçları detaylı bir şekilde incelenmiştir. Bu modellerin doğruluk, hassasiyet, duyarlılık ve f1 skoru gibi performans metrikleri üzerinden değerlendirilmesi yapılmış ve elde edilen sonuçlar Plant Pathology 2020 ve 2021 veri setleri üzerindeki test sonuçlarıyla karşılaştırılmıştır. Bu karşılaştırma, modellerin laboratuvar koşullarındaki ve gerçek dünya koşullarındaki performanslarını kıyaslamak için kritik bir rol oynamaktadır. Ayrıca Plant Pathology 2020 ve 2021 veri setleri üzerinde eğitim yapıldığında başarımların elde edilebileceği gösterilmektedir.

Derin öğrenme modellerinin eğitimi sırasında belirli hiperparametreler kullanılmıştır. Batch size 32, optimizör olarak Stochastic Gradient Descent (SGD), öğrenme oranı 0.001, momentum değeri 0.9 ve kayıp fonksiyonu olarak Cross Entropy Loss hiperparametreleri kullanılarak model eğitimleri gerçekleştirilmiştir. Eğitim süreci, her model için 25 epoch gerçekleştirilmiştir. Hiperparametrelerin seçimi, modellerin performansını doğrudan etkileyen önemli faktörler olup, bu parametrelerin dikkatli bir şekilde belirlenmesi başarılı bir model eğitimi için kritik öneme sahiptir.

Bitki hastalıklarının tespitinde kullanılan modellerin sadece yüksek doğruluk oranlarına sahip olması yeterli olmayıp, aynı zamanda karar verme süreçlerinin de anlaşılabilir ve şeffaf olması büyük önem taşımaktadır. Bu amaçla, eğitilen modellerin karar mekanizmalarını görselleştiren açıklanabilirlik haritaları oluşturulmuş ve bu haritalar üzerinden modellerin hangi özelliklere dayanarak karar verdiği analiz edilmiştir. Özellikle, bitki yapraklarındaki belirli hastalık belirtilerinin modeller tarafından nasıl algılandığı ve bu belirtilerin karar verme sürecine nasıl katkıda bulunduğu ayrıntılı olarak incelenmiştir. Açıklanabilirlik haritaları, modellerin doğruluk ve güvenilirliğini artırmakla kalmayıp, aynı zamanda tarım uzmanlarının ve çiftçilerin modellerin çıktısını daha iyi anlamalarına ve bu çıktıları güven duymalarına olanak sağlamaktadır.

4.1. Deneysel Yöntemler

Bu çalışmada, Çizelge 4'ten görüleceği üzere bitki hastalıklarının sınıflandırılması ve gerçek hayat uygulanabilirliği için 5 farklı deneysel kurulum gerçekleştirilmiştir. İlk olarak, Deney 1'de laboratuvar ortamında elde edilmiş

PlantVillage veri seti kullanılarak modeller 5-fold çapraz doğrulama yöntemi ile eğitilmiş ve doğrulama seti üzerindeki başarımları değerlendirilmiştir. Deney 2 ve 3'te gerçek dünyadan elde edilen Plant Pathology 2020 ve 2021 veri setleri rastgele bölme yöntemi ile ayrıştırılmış ve model eğitimleri gerçekleştirilmiştir. Deney 4 ve 5'te ise PlantVillage veri setinde 5-fold yöntemi ile eğitilen modeller gerçek dünya veri setleri Plant Pathology 2020 ve 2021 veri setlerinin tamamında eğitim yapılmaksızın test edilerek modelin gerçek dünya problemlerindeki uygulanabilirlik durumu ortaya çıkarılmıştır.

Çizelge 4. Deneysel Kurulumlar

Deney Adı	Önceden Eğitilmiş Model	Eğitim Veri seti	Test Veri seti
Deney 1	ImageNet	PlantVillage (5-fold çapraz doğrulama)	
Deney 2	ImageNet	Plant Pathology 2020 %80	Plant Pathology 2020 %20
Deney 3	ImageNet	Plant Pathology 2021 %80	Plant Pathology 2021 %20
Deney 4	PlantVillage (5-fold çapraz doğrulama)	-	Plant Pathology 2020
Deney 5	PlantVillage (5-fold çapraz doğrulama)	-	Plant Pathology 2021

4.2. Deney 1 Sonuçlar

Deney 1'de gösterildiği gibi; ilk olarak laboratuvar ortamından elde edilen veriler üzerindeki başarımları görmek için PlantVillage veri seti üzerinde 5-fold çapraz doğrulama ile 7 farklı derin öğrenme yöntemi olmak üzere toplamda 35 model eğitilmiştir. Eğitilen modeller doğrulama seti üzerinde test edilerek başarımları ölçülmüştür. Her bir derin öğrenme yöntemi için 5-fold'un ortalaması alınarak nihai sonuç verilmiştir. Her bir model için elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve f1 skoru metrikleri Çizelge 5'te sunulmuştur. Her bir derin öğrenme modelinin doğruluk değerleri incelenmiş ve modellerin genel sınıflandırma başarımları değerlendirilmiştir. Sınıflandırma başarımları %99,81 ile en yüksek model DenseNet201 modelidir. Ancak doğruluk genel bir sonuç vermemektedir. Ardından, hassasiyet ve duyarlılık değerleri üzerinden modellerin doğru pozitif tespit oranları ve yanlış pozitif tespit oranları karşılaştırılmıştır. F1 skoru, hassasiyet ve duyarlılık değerleri arasındaki dengeyi temsil ettiği için, modellerin genel

performansını değerlendirmek amacıyla kullanılmıştır. %99,74 f1 skor değeri ile en başarılı model DenseNet201 olarak görünmektedir. En başarısız model ise %99,11 f1 skor ile ViT Large 32 olarak görünmektedir.

Çizelge 5. PlantVillage Veri seti üzerinde 5-Fold Çapraz Doğrulama Ortalama Model Sonuçları

Model	PlantVillage			
	Doğruluk	Hassasiyet	Duyarlılık	f1 - skor
ResNet152	99.79	99.72	99.72	99.72
VGG16	99.69	99.61	99.58	99.60
DenseNet201	99.81	99.74	99.74	99.74
EfficientNet-B0	99.77	99.71	99.71	99.71
EfficientNet-B1	99.74	99.67	99.64	99.65
GoogLeNet	99.54	99.43	99.39	99.41
ViT Large 32	99.27	99.13	99.10	99.11

4.3. Deney 2-3 Sonuçları

Deney 2 ve Deney 3'ten görüleceği üzere Plant Pathology 2020 ve 2021 verisetleri rastgele bölme yöntemi ile eğitim ve test olarak ayrıştırılmıştır. 7 farklı derin öğrenme yöntemi eğitim seti üzerinde eğitilip test seti üzerinde test edilerek model karşılaştırılması yapılmıştır. Plant Pathology 2020 ve 2021 verisetleri için sırasıyla eğitilen her bir modelin test seti üzerinde elde ettiği doğruluk, hassasiyet, duyarlılık ve f1 skoru metrikleri Çizelge 6 ve 7'de gösterilmektedir.

Plant Pathology 2020 veriseti üzerinde eğitilen modellerin sonuçları değerlendirildiğinde; ResNet152 ve EfficientNet-B1 modelleri, tüm metriklerde en yüksek değerlere sahip olarak dikkat çekmektedir. Her iki model de %98,56 doğruluk oranı, sırasıyla %98,57 ve %98,60 hassasiyet, %98,56 duyarlılık ve %98,57 f1 skoru ile en üst düzey performansı sergilemiştir. Bu modellerin metrikler arasındaki tutarlılığı, sınıflandırma görevlerinde son derece başarılı olduklarını göstermektedir. ViT Large 32 modeli ise diğer modellere kıyasla en düşük performansı sergilemiştir. %93,10 doğruluk oranı, %93,31 hassasiyet, %93,10 duyarlılık ve %93,14 f1 skoru değerleriyle bu model, diğer derin öğrenme mimarilerine göre oldukça geride kalmıştır. ViT Large 32 modelinin bu düşük performansı, özellikle bu veri setinde Transformer tabanlı yaklaşımların sınıflandırma görevlerinde daha az etkili olabileceğini göstermektedir.

Plant Pathology 2021 veriseti üzerinde eğitilen modellerin sonuçları değerlendirildiğinde; DenseNet201 modeli, %98,76 doğruluk, %98,76 hassasiyet, %98,76 duyarlılık ve %98,76 f1 skoru ile tüm metriklerde en yüksek performansı

sergileyen model olarak öne çıkmaktadır. Bu veri seti üzerindeki en düşük performans gösteren model ViT Large 32 olmuştur. ViT Large 32 modeli, %92,38 doğruluk, %92,38 hassasiyet, %92,37 duyarlılık ve %92,37 f1-skoru ile diğer modellere göre daha düşük performans sergilemiştir. ViT Large 32 modelinin bu metriklerdeki performansı, diğer modellere kıyasla daha az başarılı olduğunu göstermektedir.

Çizelge 6. Plant Pathology 2020 Test Seti Model Sonuçları

Model	PlantVillage			
	Doğruluk	Hassasiyet	Duyarlılık	f1 - skor
ResNet152	98.56	98.57	98.56	98.57
VGG16	97.99	98.06	97.99	97.99
DenseNet201	98.28	98.33	98.28	98.28
EfficientNet-B0	97.99	98.01	97.99	97.99
EfficientNet-B1	98.56	98.60	98.56	98.57
GoogLeNet	97.41	97.44	97.41	97.42
ViT Large 32	93.10	93.31	93.10	93.14

Çizelge 7. Plant Pathology 2021 Test Seti Model Sonuçları

Model	PlantVillage			
	Doğruluk	Hassasiyet	Duyarlılık	f1 - skor
ResNet152	98.55	98.55	98.55	98.55
VGG16	98.69	98.70	98.69	98.69
DenseNet201	98.76	98.76	98.76	98.76
EfficientNet-B0	98.72	98.73	98.72	98.72
EfficientNet-B1	98.69	98.69	98.69	98.69
GoogLeNet	97.83	97.83	97.83	97.83
ViT Large 32	92.38	92.38	92.37	92.37

4.3. Deney 4-5 Sonuçlar

Çizelge 4'ten görüleceği üzere Deney 4 ve Deney 5,

Deney 1'de 5-fold çapraz doğrulama yöntemi ile PlantVillage veri seti üzerinde bitki hastalıklarının sınıflandırılması için eğitilen modellerin gerçek hayat veri setleri Plant Pathology 2020 ve 2021 üzerinde eğitim yapılmaksızın test edilmesi işlemleri Deney 4 ve Deney 5'te gerçekleştirilmiştir. Deney 4 ve Deney 5, 5-fold eğitilen her bir derin öğrenme yöntemi için Plant Pathology 2020 ve 2021 veri setleri üzerinde 5 farklı test işlemi gerçekleştirilmiştir. Yöntemlerin her biri için 5 farklı fold sonucunun ortalaması alınarak Çizelge 8 ve Çizelge 9'da gerçek hayat veri setleri üzerindeki ortalama model sonuçları gösterilmiştir.

Çizelge 8 incelendiğinde; farklı modellerin güçlü ve zayıf yönlerini değerlendirerek, belirli bir uygulama için en uygun modeli seçmek mümkündür. Yüksek hassasiyet gerektiren durumlar için %90,72 hassasiyet oranı ile ResNet152 gibi modeller tercih edilebilirken, genel doğruluk ve duyarlılık açısından dengeli bir model gerektiğinde %31,10 doğruluk oranı ile VGG16 veya genelleştirilebilirliği yüksek bir model gerektiğinden %39,26 f1 skoru ile DenseNet201 daha uygun olabilir. VGG16 ve DenseNet201 modelleri, dengeli ve diğer modellere göre daha yüksek performansları ile öne çıkmaktadır. ViT Large 32 ise bu veri setinde tüm metriklerde en düşük performans gösteren modeldir.

Çizelge 9 incelendiğinde; aynı şekilde farklı modellerin güçlü ve zayıf yönlerini değerlendirerek, belirli bir uygulama için en uygun modeli seçmek mümkündür. Yüksek hassasiyet gerektiren durumlar için %67,68 hassasiyet oranı ile ResNet152 gibi modeller tercih edilebilirken, genel doğruluk ve duyarlılık açısından dengeli bir model gerektiğinde %35,39 başarı oranı ile EfficientNet-B1 veya genelleştirilebilirliği yüksek bir model gerektiğinde %37,46 f1 skoru ile EfficientNet-B1 daha uygun olabilir. EfficientNet-B1 modeli, dengeli ve yüksek performansları ile öne çıkmaktadır. ViT Large 32 ise bu veri setinde tüm metriklerde en düşük performans gösteren modeldir.

Bu sonuçlar, PlantVillage veri seti ile eğitilen modellerin laboratuvar koşullarında çok yüksek performans sergilediğini ancak gerçek dünya veri setleri olan Plant Pathology 2020 ve 2021 veri setleri üzerinde düşük performans gösterdiğini ortaya koymaktadır. Bu durum, modellerin genelleme yeteneğinin yetersiz olduğunu ve gerçek dünya koşullarında uygulanabilirliklerinin sınırlı olduğunu göstermektedir. Özellikle, PlantVillage veri setindeki yüksek performans değerlerine rağmen, bu modellerin farklı çevresel koşullar, farklı ışıklandırma ve çeşitli bitki türleri içeren gerçek dünya veri setlerinde aynı başarıyı sürdüremediği anlaşılmaktadır.

Çizelge 8. PlantPathology 2020 Veri Seti Ortalama Model Sonuçları

Model	Plant Pathology 2020			
	Doğruluk	Hassasiyet	Duyarlılık	f1 - skor
ResNet152	22,86	90,72	22,85	33,49
VGG16	31,10	87,14	31,10	38,23
DenseNet201	27,08	85,80	27,08	39,26
EfficientNet-B0	18,94	87,46	18,94	28,99
EfficientNet-B1	29,37	81,60	29,37	39,03
GoogLeNet	21,68	78,40	21,68	32,17
ViT Large 32	14,94	72,03	14,94	17,97

Çizelge 9. PlantPathology 2021 Veri Seti Ortalama Model Sonuçları

Model	Plant Pathology 2021			
	Doğruluk	Hassasiyet	Duyarlılık	f1 - skor
ResNet152	15,50	67,68	15,50	23,82
VGG16	31,79	61,42	31,79	34,17
DenseNet201	21,34	60,92	21,34	30,12
EfficientNet-B0	20,77	63,52	20,77	29,12
EfficientNet-B1	35,39	60,73	35,39	37,46
GoogLeNet	17,39	53,34	17,39	21,16
ViT Large 32	3,62	59,99	3,62	5,83

4.4. Açıklanabilirlik Sonuçları


































PlantVillage veri seti kullanılarak eğitilmiş derin öğrenme modellerinin açıklanabilirlik haritalarına ilişkin karşılaştırmalı analizler Çizelge 10'da sunulmuştur. Bu analizler, modellerin karar verme süreçlerinde hangi özelliklere ve alanlara odaklandığını derinlemesine incelememizi sağlamaktadır. Modellerin bu tür haritalarla görselleştirilmesi, modelin "neye" odaklandığını, hangi görsel ipuçlarını kritik bulduğunu ve nasıl bir karar alma mekanizması geliştirdiğini anlamak açısından son derece değerlidir.

Çizelge 10'a göre, ResNet152 ve GoogLeNet modelleri, doğru hastalık sınıfını belirlerken daha geniş bir alanı taramaktadır. Bu modellerin geniş bir perspektif ile karar vermesi, sadece hastalık bölgesine değil, çevresel faktörlere de dikkat ederek daha bütüncül bir yaklaşım benimsediklerini göstermektedir. Bu durum, modelin genel sınıflandırma yeteneğine olumlu katkı sağlayarak, çeşitli görüntülerde doğru sonuca ulaşma olasılığını artırabilir. DenseNet201, EfficientNet-B0 ve EfficientNet-B1 modelleri ise açıklanabilirlik haritalarında daha dar ve spesifik alanlara, özellikle hastalıklı bölgelere odaklanmaktadır. Bu modellerin sınıflandırma işlemi sırasında hastalık belirtilerine yönelik daha keskin bir dikkat geliştirdikleri görülmektedir. Bu odaklanma, söz konusu modellerin yüksek doğrulukla belirli hastalıkları tespit edebilme yeteneklerini ortaya koymakta ve ayrıca bu dikkat alanlarının, görüntü segmentasyon problemleri için potansiyel etiketler olarak kullanılabileceğini göstermektedir. Bu durum, özellikle detaylı patolojik analizlerin gerektiği durumlarda bu modellerin üstünlüğünü işaret etmektedir. VGG16 modeli, her ne kadar yüksek performans sergileyerek doğru hastalık sınıfını belirlemiş olsa da, açıklanabilirlik haritalarının incelenmesi, modelin odaklandığı alanların hastalıkla doğrudan ilgili olmayan bölgeler olduğunu ortaya

koymaktadır. Bu, modelin doğru karara yanlış sinyaller üzerinden ulaştığını ve muhtemelen hatalı bir öğrenme süreci geliştirdiğini düşündürmektedir. VGG16'nın bu davranışı, derin öğrenme modelinin eğitim sürecinde, belki de fazla öğrenme (overfitting) ya da yanlış sinyallerden etkilenme gibi problemler yaşadığını göstermektedir. Bu tür hatalı öğrenme süreçleri, modelin farklı veri setlerinde veya gerçek dünyadaki görüntülerde yetersiz kalmasına yol açabilir.

Bu sonuçlar, açıklanabilirlik haritalarının, sadece modelin sınıflandırma performansını ölçmekle kalmayıp, aynı zamanda modelin karar verme süreçlerinin ne kadar güvenilir ve doğru olduğunu anlamak için de kritik bir araç olduğunu vurgulamaktadır. Modellerin bu tür analizler yoluyla değerlendirilmesi, daha güvenilir ve genellenebilir derin öğrenme sistemleri geliştirilmesi için önemli bir adım teşkil etmektedir.

Çizelge 10. PlantVillage Veri Seti Açıklanabilirlik Örnekleri

Görüntü	ResNet152	VGG16	DenseNet201	EfficientNet-B0	EfficientNet-B1	GoogLeNet
						
						
						
						
						
						



































PlantVillage veri seti üzerinde eğitilen derin öğrenme modellerinin, Plant Pathology 2020 ve 2021 veri setleri üzerinde doğrudan test edildiğinde, açıklanabilirlik haritalarındaki olumsuz değişim dikkat çekici sonuçlar ortaya koymaktadır. Çizelge 11 bu modellerin farklı veri setleri üzerindeki performanslarını görselleştirerek, modellerin karar verme süreçlerinde nasıl farklılaştığını gözler önüne sermektedir. Bu haritalar, modellerin hangi özelliklere odaklandığını ve veri setleri arasındaki farklılıkların modellerin öğrenme süreçlerini nasıl etkilediğini anlamamıza olanak tanımaktadır. Bu tür analizler, modelin genelleme yeteneğini ve çeşitli veri setlerinde nasıl performans gösterdiğini daha derinlemesine değerlendirmek için önemli bir araç sunmaktadır.

Çizelge 11'e göre ResNet152, genellikle yaprağın merkezi kısımlarında yoğunlaşmıştır. Model, özellikle yaprağın damarları ve hastalık belirtilerinin bulunduğu bölgeler üzerinde odaklanmaktadır. Bu durum, modelin yaprağın genel yapısını ve hastalığın merkezdeki belirtilerini dikkate aldığını göstermektedir. VGG16, ResNet152'ye benzer şekilde yaprağın merkezinde yoğunlaşmakla birlikte, daha geniş bir alanı kapsamaktadır. Model, yaprağın yalnızca belirli kısımlarına değil, aynı zamanda daha geniş bir bölgesine odaklanma eğilimindedir. Bu durum, modelin genel bir bakış açısıyla değerlendirme yaptığını işaret etmektedir. DenseNet201, yaprağın yüzeyindeki ince ayrıntılara ve hastalık belirtilerine dikkat çekmektedir. Model, yaprak üzerindeki küçük değişiklikleri vurgulayarak, bu değişikliklerin sınıflandırma üzerindeki etkisini göstermektedir. Bu, DenseNet201'in hastalık tespiti sırasında yüksek düzeyde ayrıntı odaklı olduğunu göstermektedir. EfficientNet-B0, yaprağın genel yüzeyine yayılmış bir odaklanma sergilemektedir. Modelin dikkat haritaları, belirli bir noktaya yoğunlaşmaktan ziyade, yaprağın geniş alanlarına yayılmış bir şekilde odaklanmaktadır. Bu durum, modelin daha genel bir değerlendirme sürecine sahip olduğunu düşündürmektedir. EfficientNet-B1, EfficientNet-B0'a kıyasla daha belirgin ve net odaklanma noktaları göstermektedir. Bu model, yaprak üzerindeki belirgin hastalık belirtilerine odaklanarak, sınıflandırma kararlarını bu belirtiler üzerinden vermektedir. EfficientNet-B1'in daha odaklı bir dikkat haritası sunduğu gözlemlenmiştir. GoogLeNet, yaprağın büyük bir kısmına yayılmış bir odaklanma sergilemektedir. Modelin dikkat haritaları, yaprağın geniş bir bölgesine odaklanarak, sınıflandırma sürecinde daha yaygın bir perspektif kullanıldığını göstermektedir. Bu durum, modelin geniş bir çerçevede değerlendirme yapma eğiliminde olduğunu ortaya koymaktadır.

Sonuç olarak, her bir modelin hastalık belirtilerine yönelik odaklanma stratejisi farklılık göstermektedir. DenseNet201 ve EfficientNet-B1 modelleri, hastalık belirtilerini

daha belirgin bir şekilde vurgularken, GoogLeNet ve EfficientNet-B0 modelleri daha geniş bir alana yayılmış odaklanma stratejisi benimsemektedir. Bu farklılıklar, modellerin mimari yapıları ve eğitim süreçlerinde kullanılan veri setlerine bağlı olarak değişiklik gösterebilir. Yapılan analiz, modellerin sınıflandırma performanslarını değerlendirirken açıklanabilirlik haritalarının önemli bir araç olduğunu ortaya koymaktadır.

Çizelge 11. Plant Pathology Veri Seti Açıklanabilirlik Örnekleri

Görüntü	ResNet152	VGG16	DenseNet201	EfficientNet-B0	EfficientNet-B1	GoogLeNet
						
						
						
						
						
						

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu tez çalışmasında, bitki görüntülerinden bitki hastalık tespiti yapmak için açıklanabilir derin öğrenme yöntemleri eğitilmiş ve bu yaklaşımların gerçek dünya problemlerindeki kullanılabilirliği değerlendirilmiştir. Bu kapsamda elde edilen sonuçlar aşağıda özetlenmiştir:

Laboratuvar ve Gerçek Dünya Veri Setleri: Laboratuvar ortamında elde edilen veri setleri kullanılarak eğitilen modeller, yüksek doğruluk oranları ile başarılı sonuçlar vermiştir. PlantVillage veri seti ile yapılan eğitimlerde, hastalık tespiti doğruluk oranları %95'in üzerine çıkmıştır. Ancak, gerçek dünya veri setleri (Plant Pathology 2020 ve 2021) üzerinde yapılan testlerde, performansın belirgin bir şekilde düştüğü gözlemlenmiştir. Bu durum, modellerin laboratuvar ortamındaki veri ile gerçek dünya verisi arasındaki farklılıklara duyarlı olduğunu göstermektedir.

Açıklanabilirlik: Eğitilen derin öğrenme modellerinin açıklanabilirlik haritaları incelendiğinde, modellerin bitki hastalıklarına odaklanarak tahminler yaptığı ve genellikle doğru bölgeleri incelediği görülmüştür. Bu, modellerin karar verme sürecinin tarım uzmanları ve çiftçiler tarafından anlaşılabilir olmasını sağlamıştır. Ancak, gerçek dünya verisinde bu haritaların güvenilirliği azalmıştır.

Gerçek Dünya Uygulanabilirliği: Gerçek dünya veri setleri üzerinde yapılan testlerde, modellerin pratikte beklenen verimliliği sağlayamadığı tespit edilmiştir. Laboratuvar ortamında yüksek performans sergileyen modeller, gerçek dünya koşullarında aynı başarıyı gösterememiştir. Bu, laboratuvar verileri ile gerçek dünya verileri arasındaki farklılıkların daha derinlemesine incelenmesi gerektiğini ortaya koymaktadır.

5.2 Öneriler

Veri Çeşitliliğinin Artırılması: Laboratuvar ortamında elde edilen veriler ile gerçek dünya verileri arasındaki farklılıkların giderilmesi için daha çeşitli ve geniş kapsamlı veri setleri kullanılmalıdır. Farklı coğrafi bölgelerden, farklı ışık koşullarında ve farklı cihazlarla çekilmiş görüntüler toplanarak modelin genelleme yeteneği artırılabilir.

Veri Önışleme Tekniklerinin Geliřtirilmesi: Gerçek dünya verisindeki gürültü ve karmařıklığı azaltmak için daha gelişmiş veri önışleme teknikleri kullanılmalıdır. Görüntülerin normalize edilmesi, renk düzeltmeleri ve diğeri önışleme adımları, modelin performansını artırabilir.

Model Mimarilerinin İyileřtirilmesi: Gerçek dünya verisinde performansı artırmak için daha gelişmiş ve karmařık model mimarileri denenmelidir. Örneğın, transfer öğrenme yöntemleri ve önceden eğitilmiş modeller kullanılarak gerçek dünya verisine uyum sağlanabilir.

Açıklanabilirlik Araçlarının Geliřtirilmesi: Modellerin açıklanabilirliğini artırmak için yeni araçlar ve yöntemler geliştirilmelidir. Bu, modellerin karar süreçlerinin daha iyi anlaşılmasını ve güvenilirliğın artırılmasını sağlayacaktır.

Alan Uzmanları ile İş Birliğı: Tarım uzmanları ve çiftçiler ile daha yakın iş birliğı yapılarak, modellerin gerçek dünya koşullarında test edilmesi ve geri bildirimlerin alınması sağlanmalıdır. Bu, modellerin pratikteki uygulanabilirliğini ve verimliliğini artıracaktır.

Açık Kaynak Paylaşım: Bu çalışmada elde edilen modellerin ve yöntemlerin açık kaynak olarak paylaşılması, bu alanda çalışacak diğeri arařtırmacılar için değerli bir kaynak oluřturacaktır. Bu, aynı zamanda topluluk geri bildirimleri ile modellerin sürekli iyileřtirilmesine katkıda bulunacaktır.

Mobil Uygulama Geliřtirilmesi: Bitki hastalıklarının erken teşhisi için derin öğrenme yöntemlerini içeren bir mobil uygulama geliştirilmesi, tarım sektöründe önemli bir yenilik olarak değerlendirilebilir. Bu tür bir uygulama, çiftçilere ve tarım uzmanlarına sahada anında hastalık teşhisi yapma imkânı sağlayarak, zararlı etkilerin en aza indirilmesine katkıda bulunabilir. Ayrıca, kullanıcı dostu bir arayüzle tasarlanacak bu uygulama, açıklanabilirlik haritalarını da içerebilir; böylece kullanıcılar, modelin kararlarını daha iyi anlayabilir ve bu kararların güvenilirliğine daha fazla güven duyabilirler. Bu tür bir mobil uygulama, geniş çapta kullanıma sunulduğunda, tarımda teknolojinin etkinliğini artırabilir ve bitki hastalıklarının erken teşhisinde devrim niteliğinde bir adım olabilir.

Sonuç olarak, bu tez çalışması kapsamında eğitilen derin öğrenme modelleri, kontrollü laboratuvar ortamında yüksek doğruluk ve güvenilirlik ile başarılı sonuçlar vermiştir. Ancak, bu modellerin gerçek dünya koşullarında aynı başarıyı gösterememesi,

veri setlerinin çeşitliliği ve karmaşıklığının model performansı üzerindeki kritik etkisini ortaya koymuştur.

Laboratuvar ortamında kullanılan PlantVillage veri seti, ideal ve homojen koşullar altında toplanmış olup, modellerin eğitimi ve test edilmesi sürecinde yüksek performans sağlamıştır. Bu veri seti üzerinde yapılan deneylerde, hastalık tespiti doğruluk oranları %95'in üzerine çıkmış, açıklanabilirlik haritaları ile modellerin doğru bölgelere odaklandığı gözlemlenmiştir. Bu durum, kontrollü veri koşullarında derin öğrenme yöntemlerinin potansiyelini ve gücünü göstermektedir.

Ancak, gerçek dünya veri setleri olan Plant Pathology 2020 ve 2021 üzerinde yapılan testlerde, modellerin performansında belirgin bir düşüş yaşanmıştır. Bu veri setleri, farklı ışık koşulları, çeşitli çekim açıları ve farklı kalitede görüntüler içerdiğinden, laboratuvar ortamındaki homojen veriye kıyasla çok daha heterojen ve karmaşık bir yapı sergilemiştir. Modellerin, bu karmaşıklık ve çeşitlilik karşısında yetersiz kalması, laboratuvar ortamındaki veriler ile gerçek dünya verileri arasındaki farklılıkların derinlemesine incelenmesi gerektiğini ortaya koymaktadır.

Gerçek dünya koşullarında modellerin düşük performans göstermesi, özellikle tarım uygulamalarında bu tür teknolojilerin güvenilirliğini sorgulanabilir hale getirmektedir. Tarım uzmanları ve çiftçilerin, bu teknolojilere güvenebilmesi ve etkin bir şekilde kullanabilmesi için modellerin çeşitli ve geniş kapsamlı veri setleri ile eğitilmesi gerekmektedir. Farklı coğrafi bölgelerden, çeşitli iklim koşullarında ve farklı cihazlarla elde edilen görüntüler, modelin genelleme yeteneğini artırarak gerçek dünya koşullarına daha iyi uyum sağlamasını mümkün kılabilir.

Bu bağlamda, bu çalışma, derin öğrenme modellerinin laboratuvar ortamında sağladığı başarıyı, gerçek dünya koşullarında tekrarlamak için daha fazla veri çeşitliliği ve gelişmiş yöntemlerin kullanılması gerektiğini vurgulamaktadır. Gelecekte yapılacak çalışmaların, veri çeşitliliğini artırma, daha karmaşık ve uyarlanabilir model mimarileri geliştirme ve gelişmiş veri ön işleme teknikleri kullanma gibi konulara odaklanması, bu alandaki önemli bir araştırma boşluğunu doldurabilir. Bu yöndeki ilerlemeler, derin öğrenme yöntemlerinin tarım sektöründe daha geniş ve güvenilir bir şekilde kullanılabilmesine katkı sağlayacaktır. Ayrıca, laboratuvar ortamında veya sentetik veriler ile yapılan eğitimlerin, gerçek dünya koşullarındaki karmaşıklığı ve çeşitliliği yeterince yansıtamadığı, dolayısıyla pratik uygulamalarda beklenen başarıyı sağlayamayacağı açıktır. Bu durum, sadece kontrollü ve homojen veri setleriyle eğitilmiş modellerin, gerçek dünya problemlerine uygulanabilirliğinin sınırlı olduğunu

göstermektedir. Bu nedenle, daha gerçekçi ve çeşitli veri setleri ile eğitim ve test süreçlerinin gerçekleştirilmesi, bu alandaki çalışmaların başarısını ve güvenilirliğini artıracaktır.



6. KAYNAKLAR

- Ahila Priyadharshini, R., Arivazhagan, S., Arun, M., & Mirmalini, A. (2019). Maize leaf disease classification using deep convolutional neural networks. *Neural Computing and Applications*, 31, 8887-8895.
- Ahmed, A. A., & Reddy, G. H. (2021). A mobile-based system for detecting plant leaf diseases using deep learning. *AgriEngineering*, 3(3), 478-493.
- Atila, Ü., Uçar, M., Akyol, K., & Uçar, E. (2021). Plant leaf disease classification using EfficientNet deep learning model. *Ecological Informatics*, 61, 101182.
- Borhani, Y., Khoramdel, J., & Najafi, E. (2022). A deep learning based approach for automated plant disease classification using vision transformer. *Scientific Reports*, 12(1), 11554.
- Camalan, S., Mahmood, H., Binol, H., Araujo, A. L. D., Santos-Silva, A. R., Vargas, P. A., ... & Gurcan, M. N. (2021). Convolutional neural network-based clinical predictors of oral dysplasia: Class activation map analysis of deep learning results. *Cancers*, 13(6), 1291.
- Castelvecchi, D. (2016). Can we open the black box of AI?. *Nature News*, 538(7623), 20.
- Chattopadhyay, A., Sarkar, A., Howlader, P., & Balasubramanian, V. N. (2018, March). Grad-cam++: Generalized gradient-based visual explanations for deep convolutional networks. In 2018 IEEE winter conference on applications of computer vision (WACV) (pp. 839-847). IEEE.
- Chen, J., Chen, J., Zhang, D., Sun, Y., & Nanekaran, Y. A. (2020). Using deep transfer learning for image-based plant disease identification. *Computers and Electronics in Agriculture*, 173, 105393.
- Chlap, P., Min, H., Vandenberg, N., Dowling, J., Holloway, L., & Haworth, A. (2021). A review of medical image data augmentation techniques for deep learning applications. *Journal of Medical Imaging and Radiation Oncology*, 65(5), 545-563.
- Chohan, M., Khan, A., Chohan, R., Katpar, S. H., & Mahar, M. S. (2020). Plant disease detection using deep learning. *International Journal of Recent Technology and Engineering*, 9(1), 909-914.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Houlsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.
- Eelbode, T., Sinonquel, P., Maes, F., & Bisschops, R. (2021). Pitfalls in training and validation of deep learning systems. *Best Practice & Research Clinical Gastroenterology*, 52, 101712.

- Fu, R., Hu, Q., Dong, X., Guo, Y., Gao, Y., & Li, B. (2020). Axiom-based grad-cam: Towards accurate visualization and explanation of cnns. arXiv preprint arXiv:2008.02312.
- Geetharamani, G., & Pandian, A. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers & Electrical Engineering*, 76, 323-338.
- Gorriz, J. M., Segovia, F., Ramirez, J., Ortiz, A., & Suckling, J. (2024). Is K-fold cross validation the best model selection method for Machine Learning?. arXiv preprint arXiv:2401.16407.
- Hassan, S. M., Maji, A. K., Jasiński, M., Leonowicz, Z., & Jasińska, E. (2021). Identification of plant-leaf diseases using CNN and transfer-learning approach. *Electronics*, 10(12), 1388.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Hossin, M., & Sulaiman, M. N. (2015). A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2), 1.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Hughes, D., & Salathé, M. (2015). An open access repository of images on plant health to enable the development of mobile disease diagnostics. arXiv preprint arXiv:1511.08060.
- Jiang, P. T., Zhang, C. B., Hou, Q., Cheng, M. M., & Wei, Y. (2021). Layercam: Exploring hierarchical class activation maps for localization. *IEEE Transactions on Image Processing*, 30, 5875-5888.
- Kahlout, K. M., & Ekler, P. (2021). Algorithmic splitting: A method for dataset preparation. *IEEE Access*, 9, 125229-125237.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90.
- Karakoyun, M. (2024). Artificial neural network training using a multi selection artificial algae algorithm. *Engineering Science and Technology, an International Journal*, 53, 101684.
- Kilic, Ahmet & Karakoyun, Murat. (2023). Plant Diseases Detection Using Explainable Deep Learning Methods and Its Applicability in Real Life.

- Kumar, Y., Singh, R., Moudgil, M. R., & Kamini. (2023). A systematic review of different categories of plant disease detection using deep learning-based approaches. *Archives of Computational Methods in Engineering*, 30(8), 4757-4779.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541-551.
- Liu, S., Roemer, F., Ge, Y., Bedrick, E. J., Li, Z. M., Guermazi, A., ... & Sun, X. (2023). Comparison of evaluation metrics of deep learning for imbalanced imaging data in osteoarthritis studies. *Osteoarthritis and Cartilage*, 31(9), 1242-1248.
- Mikołajczyk, A., & Grochowski, M. (2018, May). Data augmentation for improving deep learning in image classification problem. In 2018 international interdisciplinary PhD workshop (IIPhDW) (pp. 117-122). IEEE.
- Mohameth, F., Bingcai, C., & Sada, K. A. (2020). Plant disease detection with deep learning and feature extraction using plant village. *Journal of Computer and Communications*, 8(6), 10-22.
- Moupojou, E., Tagne, A., Retraint, F., Tadonkemwa, A., Wilfried, D., Tapamo, H., & Nkenlifack, M. (2023). FieldPlant: A dataset of field plant images for plant disease detection and classification with deep learning. *IEEE Access*, 11, 35398-35410.
- Mridha, K., Shaw, R. N., & Ghosh, A. (2021, September). Intelligent based waste management awareness developed by transfer learning. In 2021 IEEE 4th International Conference on Computing, Power and Communication Technologies (GUCON) (pp. 1-5). IEEE.
- Muhammad, M. B., & Yeasin, M. (2020, July). Eigen-cam: Class activation map using principal components. In 2020 international joint conference on neural networks (IJCNN) (pp. 1-7). IEEE.
- Nayak, D. R., Padhy, N., Mallick, P. K., Zymbler, M., & Kumar, S. (2022). Brain tumor classification using dense efficient-net. *Axioms*, 11(1), 34.
- Nazarov, P. A., Baleev, D. N., Ivanova, M. I., Sokolova, L. M., & Karakozova, M. V. (2020). Infectious plant diseases: etiology, current status, problems and prospects in plant protection. *Acta naturae*, 12(3), 46.
- Ouhami, M., Hafiane, A., Es-Saady, Y., El Hajji, M., & Canals, R. (2021). Computer vision, IoT and data fusion for crop disease detection using machine learning: A survey and ongoing research. *Remote Sensing*, 13(13), 2486.
- Picek, L., Šulc, M., Matas, J., Heilmann-Clausen, J., Jeppesen, T. S., & Lind, E. (2022). Automatic fungi recognition: deep learning meets mycology. *Sensors*, 22(2), 633.
- Plant Pathology (2020), url: <https://www.kaggle.com/competitions/plant-pathology-2020-fgvc7>, erişim tarihi: 2024

- Plant Pathology (2021), url: <https://www.kaggle.com/competitions/plant-pathology-2021-fgvc8>, erişim tarihi: 2024
- Quach, L. D., Quoc, K. N., Quynh, A. N., Thai-Nghe, N., & Nguyen, T. G. (2023). Explainable deep learning models with gradient-weighted class activation mapping for smart agriculture. *IEEE Access*, 11(August), 83752-83762.
- Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1), 6086.
- Ras, G., Xie, N., Van Gerven, M., & Doran, D. (2022). Explainable deep learning: A field guide for the uninitiated. *Journal of Artificial Intelligence Research*, 73, 329-396.
- Russel, N. S., & Selvaraj, A. (2022). Leaf species and disease classification using multiscale parallel deep CNN architecture. *Neural Computing and Applications*, 34(21), 19217-19237.
- Saeed, F., Khan, M. A., Sharif, M., Mittal, M., Goyal, L. M., & Roy, S. (2021). Deep neural network features fusion and selection based on PLS regression with an application for crops diseases classification. *Applied Soft Computing*, 103, 107164.
- Saleem, M. H., Potgieter, J., & Arif, K. M. (2020). Plant disease classification: A comparative evaluation of convolutional neural networks and deep learning optimizers. *Plants*, 9(10), 1319.
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision* (pp. 618-626).
- Shaikh, T. A., Rasool, T., & Lone, F. R. (2022). Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming. *Computers and Electronics in Agriculture*, 198, 107119.
- Shih, P. C., Hsu, C. C., & Tien, F. C. (2020). Automatic reclaimed wafer classification using deep learning neural networks. *Symmetry*, 12(5), 705.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Singh, D., & Singh, B. (2020). Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, 97, 105524.
- Steingrimsson, B., Fan, X., Kulkarni, A., Gao, M. C., & Liaw, P. K. (2021). Machine learning and data analytics for design and manufacturing of high-entropy materials exhibiting mechanical or fatigue properties of interest. *High-Entropy Materials: Theory, Experiments, and Applications*, 115-238.

- Sun, K. H., Huh, H., Tama, B. A., Lee, S. Y., Jung, J. H., & Lee, S. (2020). Vision-based fault diagnostics using explainable deep learning with class activation maps. *IEEE Access*, 8, 129169-129179.
- Sundaram, A., Masud, A., AlMarhoon, A., & Sarmah, B. (2022). TRANSFER LEARNING APPROACH FOR CLASSIFICATION OF WIDELY USED SPICES. *Yanbu Journal of Engineering and Science*, 19(2), 1-21.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Talebi, H., & Milanfar, P. (2021). Learning to resize images for computer vision tasks. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 497-506).
- Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- Thakur, P. S., Chaturvedi, S., Khanna, P., Sheorey, T., & Ojha, A. (2023). Vision transformer meets convolutional neural network for plant disease classification. *Ecological Informatics*, 77, 102245.
- Thakur, P. S., Khanna, P., Sheorey, T., & Ojha, A. (2021, December). Vision transformer for plant disease detection: PlantViT. In *International Conference on Computer Vision and Image Processing* (pp. 501-511). Cham: Springer International Publishing.
- Thakur, P. S., Khanna, P., Sheorey, T., & Ojha, A. (2022). Explainable vision transformer enabled convolutional neural network for plant disease identification: PlantXViT. *arXiv preprint arXiv:2207.07919*.
- Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272-279.
- Tummala, S., Kadry, S., Bukhari, S. A. C., & Rauf, H. T. (2022). Classification of brain tumor from magnetic resonance imaging using vision transformers ensembling. *Current Oncology*, 29(10), 7498-7511.
- Ueda, D., Yamamoto, A., Takashima, T., Onoda, N., Noda, S., Kashiwagi, S., ... & Miki, Y. (2021). Training, validation, and test of deep learning models for classification of receptor expressions in breast cancers from mammograms. *JCO Precision Oncology*, 5, 543-551.
- Vallabhajosyula, S., Sistla, V., & Kolli, V. K. K. (2022). Transfer learning-based deep ensemble neural network for plant leaf disease detection. *Journal of Plant Diseases and Protection*, 129(3), 545-558.

- Wang, G., Sun, Y., & Wang, J. (2017). Automatic image-based plant disease severity estimation using deep learning. *Computational intelligence and neuroscience*, 2017.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Wani, J. A., Sharma, S., Muzamil, M., Ahmed, S., Sharma, S., & Singh, S. (2022). Machine learning and deep learning based computational techniques in automatic agricultural diseases detection: Methodologies, applications, and challenges. *Archives of Computational methods in Engineering*, 29(1), 641-677.
- Wei, K., Chen, B., Zhang, J., Fan, S., Wu, K., Liu, G., & Chen, D. (2022). Explainable deep learning study for leaf disease classification. *Agronomy*, 12(5), 1035.
- Xiong, Z., Cui, Y., Liu, Z., Zhao, Y., Hu, M., & Hu, J. (2020). Evaluating explorative prediction power of machine learning algorithms for materials discovery using k-fold forward cross-validation. *Computational Materials Science*, 171, 109203.
- Yoon, H. (2021). Finding unexpected test accuracy by cross validation in machine learning. *International Journal of Computer Science & Network Security*, 21(12spc), 549-555.
- Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2921-2929).