



Comparative Analysis of Deep Learning Architectures for Plant Leaf Disease Detection

Emin Ünlü^a , Soydan Serttaş^{*b}

ABSTRACT

In recent years, significant progress has been made in effectively using deep learning techniques for the diagnosis and classification of foliar diseases in plants. This study compares the performance of five different deep learning models - VGG16, InceptionV3, AlexNet, MobileNetV2, and a specially developed CNN architecture - in terms of their ability to diagnose and classify foliar diseases in plants. The dataset was subjected to horizontal and vertical rotations to enhance the models' generalisation ability, and data augmentation methods such as brightness adjustments and noise addition were employed. A total of 13,716 images were analysed, split into 70% for training, 20% for validation, and 10% for testing. According to the results obtained, the InceptionV3 model demonstrated the highest performance with an accuracy rate of 97.37% on the test data. This study highlights the importance of deep learning approaches in the early and accurate diagnosis of plant diseases, revealing that these methods can help farmers and agricultural experts minimise production losses and promote healthy plant growth. The comparative analysis provides valuable insights for developing intelligent, customised agricultural surveillance systems.

^a Kütahya Dumlupınar University,
Engineering Faculty,
Dept. of Computer Engineering
43100 - Kütahya, Türkiye
ORCID: 0009-0005-5493-8154

^{b,*} Kütahya Dumlupınar University,
Engineering Faculty,
Dept. of Computer Engineering
43100 - Kütahya, Türkiye
ORCID: 0000-0001-8887-8675

*Corresponding author.
e-mail: soydan.serttas@dpu.edu.tr

Bitki Yaprak Hastalığı Tespiti için Derin Öğrenme Mimarilerinin Karşılaştırmalı Analizi

ÖZ

Son yıllarda, özellikle bitkilerde görülen yaprak hastalıklarının teşhis ve sınıflandırılmasında derin öğrenme tekniklerinin etkin kullanımıyla önemli ilerlemeler kaydedilmiştir. Bu çalışmada, beş farklı derin öğrenme modeli - VGG16, InceptionV3, AlexNet, MobileNetV2 ve özel olarak geliştirilen bir CNN mimarisi - performans açısından karşılaştırılmıştır. Modelin genelleme yeteneğini artırmak amacıyla veri kümesine yatay ve dikey döndürmeler uygulanmış; ayrıca parlaklık ayarları ve gürültü ekleme gibi veri artırma yöntemleri kullanılmıştır. Toplam 13.716 görüntü, %70 eğitim, %20 doğrulama ve %10 test oranlarında dengeli bir şekilde bölünerek analiz edilmiştir. Elde edilen sonuçlara göre, InceptionV3 modeli test verisi üzerinde elde ettiği %97,37 doğruluk oranı ile en yüksek performansı sergilemiştir. Bu çalışma, bitki hastalıklarının erken ve doğru teşhisinde derin öğrenme yaklaşımlarının önemine dikkat çekmekte ve bu yöntemlerin çiftçiler ile tarım uzmanları açısından üretim kayıplarını en aza indirerek sağlıklı bitki gelişimini desteklemede önemli katkılar sunduğunu ortaya koymaktadır. Yapılan karşılaştırmalı analiz, akıllı ve özelleştirilmiş tarımsal gözetim sistemlerinin geliştirilmesine yönelik değerli bilgiler sağlamaktadır.

Keywords: Leaf disease detection, deep learning, image processing, data augmentation

Anahtar Kelimeler: Yaprak hastalığı tespiti, derin öğrenme, görüntü işleme, veri artırma

Submitted: 05.09.2025
Revised: 21.12.2025
Accepted: 28.12.2025

doi:10.30855/ais.2025.08.02.03

1. Giriş (Introduction)

Bitki hastalıkları, tarımın yanı sıra gıda güvenliğinin sağlanmasında kritik bir rol oynar. Bu hastalıklar tarımsal üretimi olumsuz etkileyerek ekonomik kayıplara yol açabilir. Özellikle yaprak hastalıkları, bitkinin fotosentez kapasitesini düşürerek büyümesini engelleyebilir. Geleneksel yöntemlerle hastalık teşhisi ise zaman alıcıdır ve uzmanlık gerektirir. Bu durum erken müdahaleyi zorlaştırarak verim kaybına neden olabilir.

Son yıllarda yapay zeka ve özellikle derin öğrenme tekniklerinin gelişimi ile birlikte, tarımsal alanlarda otomatik hastalık tespiti mümkün hale gelmiştir. Görüntü işleme tekniklerinin derin öğrenme mimarileriyle birleştirilmesi sayesinde, yaprak görüntülerinden hastalık sınıflandırması yüksek doğruluk oranlarıyla gerçekleştirilebilmektedir. Derin öğrenme modelleri, görüntülerden özellik çıkarmayı otomatik olarak öğrenebildikleri için, geleneksel makine öğrenmesi yöntemlerine kıyasla çok daha etkili sonuçlar verebilmektedir.

Bu çalışmada, bitki yapraklarındaki üç farklı durumu sağlıklı, tozlu ve paslı (Healthy, Powdery and Rust) sınıflandırmak amacıyla beş farklı derin öğrenme mimarisi değerlendirilmiştir: VGG16, InceptionV3, AlexNet, MobileNetV2 ve özel olarak tasarlanmış bir CNN modeli. Tozlu (powdery) hastalığı, yaprak yüzeyinde beyazımsı toz benzeri mantar oluşumlarıyla kendini gösteren yaygın bir bitki hastalığıdır. Pas (rust) ise yapraklar üzerinde kahverengi-turuncu renkte benekler şeklinde ortaya çıkan ve genellikle mantar kaynaklı bir diğer hastalık türüdür. Veri kümesi Kaggle platformundan alınmış [1] ve görüntü çoğaltma (data augmentation) uygulanarak 13716 görüntü oluşturulmuştur. Görüntüler, %70 eğitim, %20 doğrulama ve %10 test olarak dengeli şekilde ayrılmıştır. Eğitim verilerinde görüntü çoğaltma uygulanarak modelin overfitting'e düşmesi engellenmiş ve genelleme kabiliyeti artırılmıştır. Uygulanan çoğaltma (augmentation) işlemleri; yatay ve dikey çevirme, 90-180-270 derece döndürme, parlaklık artırma/azaltma ve gürültü ekleme işlemlerini kapsamaktadır.

Bu makalede her bir model, performans metrikleriyle değerlendirilmiştir. Elde edilen sonuçlar, bitki hastalıklarının otomatik olarak ve yüksek doğrulukla tespit edilebileceğini göstermekte olup tarımsal üretimin dijitalleşmesi ve otomasyonu adına önemli katkılar sunmaktadır.

2. Önceki Çalışmalar (Previous Works)

Mohanty, Hughes ve Salathé tarafından yapılan öncü çalışmada [2], ImageNet üzerinde önceden eğitilmiş AlexNet ve GoogLeNet mimarileri kullanılmıştır. Araştırmada PlantVillage veri setindeki 14 farklı bitkiden 26 hastalık sınıfı içeren 54306 adet yaprak görüntüsü kullanılmıştır. Bu görüntüler RGB formatındadır ve veri seti sınıf dengesi gözetilerek eğitim/test olarak bölünmüştür. Transfer öğrenme yaklaşımıyla, ağların son katmanları değiştirilerek bitki hastalıkları sınıflarına göre yeniden eğitilmiştir. GoogLeNet modeli, %99.35 doğruluk oranıyla en iyi sonucu vermiştir.

Ferentinos [3], 25 farklı bitki hastalığı sınıfını içeren büyük bir veri seti üzerinde çeşitli CNN mimarilerini sıfırdan eğitmiştir. Kullanılan modeller, 3 ila 5 konvolüsyon katmanı, ReLU aktivasyonu ve maksimum havuzlama (max-pooling) işlemleri içeren standart yapılarla inşa edilmiştir. Özellikle model hiperparametrelerinin (epoch sayısı, öğrenme oranı, filtre boyutları) dikkatli şekilde optimize edilmesiyle, test doğruluğu %99.53 seviyelerine ulaşmıştır. Bu sonuç, ağ derinliği kadar veri ön işleme ve hiperparametre seçiminin önemini de vurgulamaktadır.

Too çalışmasında modern transfer öğrenme mimarileri karşılaştırılmıştır [4]. Bu mimariler ResNet50, VGG19, DenseNet121, InceptionV3, Xception ve MobileNet'tir. Çalışmada PlantVillage veri seti kullanılmış olup eğitim, validasyon ve test oranları dengeli dağıtılmıştır. Tüm modeller, ImageNet ön eğitilmiş olarak alınmış, son sınıflandırma katmanları değiştirilerek fine-tuning uygulanmıştır. ResNet50 modeli %98.2 doğruluk ile en iyi performansı sergilemiştir. Ayrıca, ResNet mimarisinin art arda gelen katmanlar arasında "skip connection" kullanması nedeniyle gradyan kaybı problemini azalttığı ve derin yapıların daha stabil öğrenmesini sağladığı açıklanmıştır.

GauthamSree ve ekibi, EfficientNet-B3 mimarisine dayanan bir sistemle bitki yaprak hastalıklarını sınıflandırmıştır [5]. Transfer öğrenme kullanarak eğitilen bu model, PlantVillage veri seti dahilinden 60.930 görüntü ile beslenmiş ve %99.875 doğruluk (accuracy), %99.871 geri çağırma (recall) ve %99.874 hassasiyet (precision) elde edilmiştir. Model, “compound scaling” yaklaşımıyla optimize edilmiş olup, yüksek doğruluk sağlarken parametre sayısını ve hesaplama yükünü minimal düzeyde tutmaya odaklanmıştır. Bu durum, mobil uygulamalara uygunluk açısından önemli bir avantaj sunmaktadır.

Lu ve arkadaşları, klasik RGB görüntüler yerine hiperspektral görüntüleme verisi kullanarak CNN mimarilerinin başarı oranını artırmıştır [6]. Kullanılan hiperspektral görüntüler 400–1000 nm dalga boyu aralığında alınmış olup, görünür ışık spektrumunun dışındaki detayları da içermektedir. Çalışmada ResNet50 ve bir 3D-CNN modeli karşılaştırılmış ve hiperspektral verilerin, sadece RGB görüntülere kıyasla %8’e kadar daha yüksek doğruluk sağladığı bulunmuştur. Bu sonuç, veri kalitesinin ve çeşitliliğinin sınıflandırma performansını doğrudan etkilediğini göstermektedir.

3. Materyal ve Metodoloji (Material and Methodology)

3.1. Veri kümesi (Dataset)

Bu çalışmada kullanılan verilerin kaynağı Kaggle platformunda yayınlanan “Bitki Hastalığı Tanıma Veri setleri” adlı açık kaynaklı bir görüntü koleksiyonudur [1]. Veri setinde; Sağlıklı (Healthy), Tozluk (Powdery - tozluk yaprak küfü), ve Pas (Rust - pas hastalığı) olmak üzere üç ayrı yaprak durumu sınıflandırması bulunmaktadır. Tozluk yaprak küfü hastalığı bitkilerin yapraklarında beyaz ve toza benzer bir tabaka oluşturan mantar enfeksiyonudur [7]. Toplamda 13716 görüntüden oluşan veri setinin bölünmesine ilişkin detaylar aşağıda belirtilmiştir:

Tablo 1. Kullanılan Veriseti Özellikleri

Model	Healthy	Powdery	Rust	Toplam
Eğitim Seti (%70)	3330	3096	3177	9603
Doğrulama Seti (%20)	945	891	909	2745
Test Seti (%10)	477	441	450	1368
Toplam	4752	4428	4536	13716

Veri seti, her sınıf için dengeli bir şekilde ayrılmış ve sınıf dengesizliğinin model performansına etkisi minimize edilmiştir. Bu dengeleme, sınıflar arası adil karşılaştırma imkânı sunmuştur.

3.2. Veri Ön İşleme (Data Preprocessing)

Model eğitime başlamadan önce görüntüler 224x224 çözünürlüğüne yeniden boyutlandırılmış ve her piksel değeri 0 ile 1 arasında normalize edilmiştir. Renkli (RGB) olan tüm resimler tensöre dönüştürülerek kanal yapısı korunmuş ve ayrıca veriler “.jpg” ve “.png” gibi formatlar arasında dönüştürülerek dosya bütünlüğü sağlanmıştır. Tüm görüntüler, kayıplı sıkıştırmanın sınıflandırma performansı üzerindeki olası olumsuz etkilerini önlemek amacıyla eğitim sürecinde JPG formatında kullanılmıştır. Bu sayede, yaprak hastalıklarına özgü doku ve renk detaylarının korunması hedeflenmiştir.

3.3. Veri Arttırma (Data Augmentation)

Modelin genelleme yeteneğini artırmak ve overfitting etkisini azaltmak için eğitim verilerine veri arttırma teknikleri [8] uygulanmıştır. Kullanılan veri arttırma prosedürleri aşağıda sıralanmıştır:

- Yatay çevirme (horizontal flip)
- Dikey çevirme (vertical flip)
- Görüntü döndürme (90°, 180°, 270°)
- Parlaklık düzenlemeleri (0.5 ve 1.5 faktörleriyle)
- Rasgele gürültü (Gaussian noise) ekleme

Veri arttırma sürecinde, eğitim setindeki her bir orijinal görüntüye döndürme, yatay ve dikey yansıtma ile ölçekleme işlemleri uygulanarak 6 adet yeni varyasyon üretilmiştir. Böylece her bir görüntü, kendisiyle

birlikte toplamda 7 görüntüye karşılık gelmektedir. Bu işlem sonucunda veri kümesinin toplam görüntü sayısı 9180'den 13.716'ya çıkarılmıştır. Veri artırma işlemi, eğitim, doğrulama ve test kümelerinin oluşturulmasından önce gerçekleştirilmiş; ardından veri kümesi %70 eğitim, %20 doğrulama ve %10 test olacak şekilde rassal olarak ayrılmıştır.

3.4. Özellik Çıkarımı (Feature Extraction)

Transfer öğrenme tekniğiyle önceden eğitilmiş modellerin son katmanları kaldırılmış, bunun yerine yeni katmanlar eklenerek özel sınıflandırıcılar oluşturulmuştur [9]. Bu yapı, VGG16, InceptionV3, AlexNet ve MobileNetV2 hazır modellerine uygulanmıştır. Bu sayede görüntülerdeki düşük seviye kenar, renk, şekil gibi özellikler otomatik olarak çıkarılarak sınıflandırmaya katkı sağlanmıştır.

3.5. Model Mimarileri (Model Architectures)


Bu çalışmada, beş farklı derin öğrenme mimarisi kullanılarak bitki yaprak hastalıklarının sınıflandırılması amaçlanmıştır. Tablo 2'de avantaj ve dezavantajları verilen bu mimariler VGG16, InceptionV3, AlexNet, MobileNetV2 ve CNN ağıdır.

Tablo 2. Bu Çalışmada Kullanılan Modellerin Avantaj ve Dezavantajları

Model	Avantajları	Dezavantajları
VGG16	Basit yapısı ve evrensel uygulanabilirliği.	Küçük uygulamalarda kullanım zordur, parametre sayısı çok yüksektir.
InceptionV3	Çok yönlü özellik çıkarımı, derin mimari yapısı.	Daha karmaşık bir yapıdır, uygulaması nispeten zordur.
Alexnet	Derin öğrenmede yüksek doğruluk	Parametre sayısı yüksektir, modern modellere göre daha az performanslıdır.
MobileNetV2	Hesaplama maliyeti düşük ve hızlı	Karmaşık görevlerde doğruluk sınırı oluşabilir.
CNN (Custom)	Hızlı, basit ve etkili	Derin mimariye göre karmaşık verilerde performans sınırlı olabilir.

3.5.1. VGG16


VGG16 mimarisi, 2014 ImageNet yarışmasında başarı gösteren bir yöntemdir. Şekil 1'de görülen bu mimari, toplamda 16 ağırlıklı katmandan oluşur: 13'ü konvolüsyon ve 3'ü fully connected katmandır. Her konvolüsyon katmanında 3x3 boyutunda küçük filtreler kullanılır. Her bloğun sonunda max pooling işlemi uygulanarak uzamsal boyut küçültülür. Aktivasyon fonksiyonu olarak ReLU tercih edilir. Bu yapı, parametre sayısı bakımından (~138 milyon) oldukça yoğundur ancak transfer öğrenmede yaygın olarak kullanılır. Avantajı, derin ve standart yapısıyla güçlü bir mimari sunmasıdır; dezavantajı ise yüksek parametre sayısı nedeniyle hafif ve kaynak kısıtlı uygulamalarda kullanımının zor olmasıdır [10].



Şekil 1. VGG16 Mimarisi [11]

3.5.2 InceptionV3


Google tarafından geliştirilen Inception mimarisi, çok ölçekli filtreleme yaklaşımını benimser. InceptionV3, 1x1, 3x3 ve 5x5 gibi farklı boyutlardaki filtreleri aynı modülde paralel olarak çalıştırarak daha fazla özellik çıkarımı sağlar. Bu mimaride ayrıca auxiliary classifier (yardımcı sınıflayıcı), batch normalization, factorized convolution gibi verimlilik artırıcı yöntemler bulunur. Parametre sayısı yüksek olmasına rağmen işlem verimliliği dikkat çekicidir. Avantajı, çok yönlü özellik çıkarımı yapabilmesi ve derin mimari yapısıyla yüksek doğruluk sağlamasıdır; dezavantajı ise yapısının karmaşıklığı nedeniyle uygulanmasının ve optimize edilmesinin görece zor olmasıdır [12].



Şekil 2. InceptionV3 Mimarisi [13]

3.5.3 AlexNet


AlexNet, 2012 ImageNet yarışmasında birinci olan ve derin öğrenmenin dönüm noktası olarak kabul edilen bir mimaridir. 5 konvolüsyon ve 3 fully connected katmandan oluşur. İlk konvolüsyon katmanında 11x11 filtreler kullanılmıştır. Aktivasyon fonksiyonu olarak ReLU kullanılmış ve overfitting'i azaltmak için dropout uygulanmıştır. Ayrıca GPU üzerinde eğitim için çift veri yolu kullanılmıştır. Avantajı, derin öğrenme alanındaki gelişmeleri başlatan öncü bir mimari olmasıdır; dezavantajı ise yüksek parametre sayısı ve modern modellere kıyasla daha düşük performans sergilemesidir [14].



Şekil 3. AlexNet Mimarisi [15]

3.5.4 MobileNetV2

MobileNetV2, özellikle mobil cihazlar ve gömülü sistemlerde çalışmak üzere optimize edilmiş bir modeldir. “Inverted residual block” yapısı sayesinde geleneksel konvolüsyonlara kıyasla çok daha az hesaplama ile benzer doğruluklara ulaşabilir. Depthwise separable convolutions kullanılarak model parametreleri ve boyutları büyük ölçüde azaltılmıştır. Avantajı, hafif yapısı ve hızlı çalışması sayesinde mobil ve gömülü sistemlerde verimli şekilde kullanılabilmesidir; dezavantajı ise karmaşık ve detaylı görevlerde doğruluk oranının sınırlı kalabilmesidir [16].



3.5.5 Özel CNN (Own CNN)

Bu çalışmaya özgü olarak oluşturulan bu özel modelde (Tablo 3); 3 konvolüsyon katmanı, her katmandan sonra max-pooling işlemi, flatten katmanı ve 2 fully connected katman yer almaktadır. Ayrıca overfitting’i önlemek amacıyla dropout katmanı eklenmiştir. Hafif yapısı sayesinde eğitim süresi oldukça kısadır ve kaynak kullanımı düşüktür. Avantajı, sade yapısıyla hızlı ve etkili sonuçlar üretebilmesidir; dezavantajı ise derin mimarilere göre karmaşık veri setlerinde sınırlı performans gösterebilmesidir [18].

Tablo 3. Bu çalışmada kullanılan CNN yapısı

Layer Type	Number of Filters	Size of Feature Map	Size of Kernel	Stride	Activation
Conv2D	32	222x222x32	3x3	1x1	ReLu
MaxPooling2D	-	111x111x32	2x2	2x2	-
Conv2D	64	109x109x64	3x3	1x1	ReLu
MaxPooling2D	-	54x54x64	2x2	2x2	-
Conv2D	128	52x52x128	3x3	1x1	ReLu
MaxPooling2D	-	26x26x128	2x2	2x2	-
Flatten	-	86528	-	-	-
Dense	-	128	-	-	ReLu
Dropout(0.5)	-	128	-	-	-
Dense(output)	-	3	-	-	Softmax

Kullanılan Hiperparametreler Tablo 4’te verilmiştir.

Tablo 4. Modellerin Eğitiminde Kullanılan Hiperparametreler

Hiperparametre	Değer
Görüntü Boyutu	224x224
Epoch Sayısı	50
Batch Boyutu	32
Öğrenme Oranı (Adam)	0.0001
Aktivasyon Fonksiyonları	ReLU, Softmax
Kayıp Fonksiyonu	Categorical Crossentropy

Tüm modeller, 50 epoch boyunca sabit öğrenme oranı (0.0001) kullanılarak Adam optimizasyon algoritması ile eğitilmiştir. Doğrulama kaybında belirgin bir aşırı öğrenme (overfitting) gözlemlenmediği için erken durdurma (early stopping) uygulanmamıştır. DeneySEL sonuçların tekrarlanabilirliğini sağlamak amacıyla eğitim sürecinde sabit bir rastgelelik tohumu (random seed) kullanılmıştır.

3.6. Eğitim Ortamı ve Performans Ölçüm Kriterleri (Training Environment and Performance Measurement Criteria)

Model eğitim süreci Google Colab üzerinde gerçekleştirilmiştir [19]. Colab ortamında GPU olarak NVIDIA Tesla T4 kullanılmış olup sistemin belleği 15 GB'tır. Yazılım içinde kullanılan kütüphaneler TensorFlow 2.x, Keras, NumPy, Scikit-learn, Matplotlib, Seaborn ve OpenCVdir.

Model başarılarının değerlendirilmesi için doğru pozitif, yanlış pozitif, doğru negatif ve yanlış negatif kavramlarına bakmak gerekir [20]:

- **Doğru Pozitif (True Positive - TP):** Modelin pozitif olarak tahmin ettiği ve gerçekte de pozitif olan örneklerdir. Yani, modelin doğru şekilde pozitif sonucu tespit etmesidir.
- **Yanlış Pozitif (False Positive - FP):** Modelin pozitif olarak tahmin ettiği ancak gerçekte negatif olan örneklerdir. Başka bir deyişle, modelin yanlışlıkla negatif bir örneği pozitif olarak sınıflandırmasıdır.
- **Doğru Negatif (True Negative - TN):** Modelin negatif olarak tahmin ettiği ve gerçekte de negatif olan örneklerdir. Modelin doğru şekilde negatif sonucu tespit etmesidir.
- **Yanlış Negatif (False Negative - FN):** Modelin negatif olarak tahmin ettiği ancak gerçekte pozitif olan örneklerdir. Yani, modelin pozitif olan bir örneği yanlışlıkla negatif sınıflandırmasıdır.

Model başarıları, aşağıdaki metriklerle değerlendirilmiştir [21]:

- **Doğruluk (Accuracy):** Modelin doğru sınıflandırdığı örneklerin tüm örneklerle oranıdır (Eşitlik 1).
- **Kesinlik (Precision):** Pozitif olarak sınıflandırılan örneklerin gerçekten pozitif olma oranıdır (Eşitlik 2).
- **Duyarlılık (Recall):** Gerçek pozitif örneklerin doğru şekilde tanınma oranıdır (Eşitlik 3).
- **F1 Skoru:** Kesinlik ve duyarlılığın harmonik ortalamasıdır (Eşitlik 4).
- **Karmaşıklık Matrisi (Confusion Matrix):** Gerçek sınıflarla tahmin edilen sınıfların karşılaştırıldığı 2D matristir. Modelin hangi sınıfları doğru ya da yanlış sınıflandırdığını gösterir.

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


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

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

$$\text{F1 Skoru (F1 Score)} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

3.7. Metodoloji (Methodology)

Bu çalışmada uygulanan yöntemsel yaklaşım, Şekil 5'de sistem mimarisi olarak özetlenmiştir. Öncelikle, çalışmada kullanılan yaprak hastalığı veri kümesi üzerinde veri ön işleme adımları gerçekleştirilmiş, ardından beş farklı derin öğrenme mimarisi (VGG16, InceptionV3, AlexNet, MobileNetV2 ve özel bir CNN modeli) ile ayrı ayrı eğitim süreçleri yürütülmüştür. Eğitilen modeller doğrulama verisi ile değerlendirilmiş ve test aşamasında nihai sınıflandırma sonuçları elde edilmiştir. Farklı mimarilerin performansları karşılaştırılarak en etkili yapının belirlenmesi hedeflenmiştir.



Şekil 5. Yaprak hastalığı tespiti için önerilen sistem mimarisi

4. Bulgular (Findings)

Bu bölümde bitki yaprağı hastalıklarının sınıflandırılması amacıyla VGG16, InceptionV3, AlexNet, MobileNetV2 ve özel tasarlanmış bir CNN mimarisi karşılaştırılmıştır. Test verileri üzerinden elde edilen sonuçlar doğruluk (accuracy), kayıp (loss), kesinlik (precision), duyarlılık (recall), F1 skoru ve karmaşıklık matrisleri bakımından değerlendirilmiş ve elde edilen bulgular aşağıda tartışılmıştır.

4.1. Model Performans Karşılaştırması-Test Verileri (Model Performance Comparison-Test Data)

Tablo 5. Modellerin performans sonuçları

Model	Test Accuracy	Test Loss	Precision	Recall	F1 Score
VGG16	0.9240	0.4049	0.9200	0.9200	0.9200
InceptionV3	0.9737	0.0827	0.9739	0.9737	0.9737
Alexnet	0.9547	0.1947	0.9600	0.9500	0.9500
MobileNetV2	0.9576	0.2907	0.9600	0.9600	0.9600
CNN (Custom)	0.9708	0.1959	0.9700	0.9700	0.9700

Tablo 5'te sunulan genel test performanslarına bakıldığında, en yüksek doğruluk oranı %97.37 ile InceptionV3 modeline aittir. Bunu sırasıyla CNN (Custom) %97.08, MobileNetV2 %95.76, AlexNet %95.47 ve VGG16 %92.40 takip etmektedir. Benzer şekilde test kaybı (loss) değerleri de en düşükten en yükseğe doğru InceptionV3 (0.0827), CNN (0.1959), AlexNet (0.1947), MobileNetV2 (0.2907) ve VGG16 (0.4049) şeklinde sıralanmıştır. Bu sonuçlar, Inception mimarisinin daha derin ve karmaşık özellikleri yakalama konusundaki başarısını açıkça ortaya koymaktadır.

Literatürde %98-99 doğruluk oranları bildiren birçok çalışma, PlantVillage gibi kontrollü çekim koşullarına sahip veri kümeleri üzerinde gerçekleştirilmiştir. Bu veri kümelerinde arka planlar sade, ışıklandırma koşulları homojen ve yaprak pozisyonları büyük ölçüde standarttır. Buna karşılık, bu çalışmada kullanılan veri kümesi farklı ışıklandırma koşulları, karmaşık arka planlar ve değişken yaprak konumlarını içermektedir. Bu durum sınıflandırma problemini daha zor hale getirmekte olup, elde edilen %97,37 doğruluk oranı, gerçek saha koşullarına daha yakın ve pratik açıdan anlamlı bir performans sunmaktadır.

Özel olarak tasarlanan üç katmanlı CNN mimarisinin InceptionV3'e oldukça yakın performans göstermesi de dikkat çekici bir sonuçtur. Bunun temel nedenlerinden biri, problemin üç sınıflı olması

ve kapsamlı veri artırma tekniklerinin uygulanmasıdır. Veri artırma sayesinde, daha sade bir mimari dahi ayırt edici özellikleri öğrenebilmiş ve yüksek genelleme başarısı elde etmiştir. Bu tür hafif modeller, özellikle kaynak kısıtlı ve gerçek zamanlı tarımsal uygulamalar için önemli bir alternatif sunmaktadır.

Tablo 6. Modellerin Macro Avg Değerleri

Model	Test Accuracy	Recall	F1 Score
VGG16	0.9300	0.9200	0.9200
InceptionV3	0.9743	0.9735	0.9738
Alexnet	0.9600	0.9600	0.9500
MobileNetV2	0.9600	0.9600	0.9600
CNN (Custom)	0.9700	0.9700	0.9700

Tablo 7. Modellerin Weighted Avg Değerleri

Model	Test Accuracy	Recall	F1 Score
VGG16	0.9200	0.9200	0.9200
InceptionV3	0.9739	0.9737	0.9737
Alexnet	0.9600	0.9500	0.9500
MobileNetV2	0.9600	0.9600	0.9600
CNN (Custom)	0.9700	0.9700	0.9700

Tablo 6 ve Tablo 7’de ise modellerin sırasıyla macro average ve weighted average metrikleri gösterilmiştir. Macro average, sınıflar arası dengesizlikten etkilenmeden her sınıfın eşit önemle değerlendirildiği bir ölçüt sağlarken; weighted average, her sınıfın örnek sayısına göre ağırlıklandırılmış sonuçlarını verir. InceptionV3 modeli, her iki metrikte de (precision, recall ve F1-score) en yüksek değerlere ulaşarak, veri setindeki her sınıfı yüksek doğrulukla sınıflandırdığını göstermiştir.

Özellikle dikkat çeken bir diğer model, özel olarak oluşturulan CNN mimarisidir. Bu model, hem macro hem de weighted ortalamalarda %97 F1 skoru ile oldukça başarılı sonuçlar elde etmiş ve InceptionV3’ten sonra ikinci sırada yer almıştır. Bu durum, özel yapılandırılmış daha sade bir mimarinin dahi dikkatli hiperparametre ayarlamaları ve veri ön işleme teknikleriyle çok yüksek başarı sağlayabileceğini ortaya koymaktadır.

VGG16 mimarisi ise diğer modellere kıyasla daha düşük performans göstermiştir. Bunun başlıca nedeni, VGG16’nın daha eski ve derinlik bakımından sınırlı bir yapı sunması ve transfer öğrenme sürecinde yeterince uyum sağlayamamasıdır. Ayrıca modelin test verilerindeki kayıp değeri de en yüksek değerlerden biri olarak öne çıkmıştır.

Yapılan tüm değerlendirmeler sonucunda, InceptionV3 modelinin bitki yaprak hastalıklarının sınıflandırılmasında en dengeli ve etkili sonuçları verdiği söylenebilir. Bu mimarinin yüksek doğruluk oranı, düşük kayıp değeri ve güçlü sınıf ayrımı yeteneği, tarım uygulamalarında hızlı ve güvenilir bir tanı sistemi olarak kullanılabileceğini göstermektedir. Diğer taraftan, düşük kaynaklı sistemlerde özel olarak tasarlanmış bir CNN mimarisi de oldukça iyi bir alternatif sunmaktadır.


Model performanslarını daha iyi kavrayabilmek adına her mimarinin karmaşıklık matrisi (confusion matrix) Şekil 6-10’da verilmiştir. Bu görseller, modellerin hangi sınıflarda başarılı veya zayıf olduğunu açıkça göstermektedir.

Modellerin pratik uygulanabilirliğini değerlendirebilmek amacıyla hesaplama maliyetleri de dikkate alınmıştır. InceptionV3 modeli en yüksek doğruluğu sağlamasına rağmen daha karmaşık bir yapıya sahiptir. Buna karşılık, MobileNetV2 ve özel tasarım CNN modelleri daha düşük parametre sayıları sayesinde daha hızlı çıkarım süresi sunmakta ve mobil ya da gömülü sistemlerde kullanım için daha uygun bir yapı sergilemektedir.

Tablo 8. Modellerin Hesaplama Maliyeti ve Pratik Uygulanabilirlik Karşılaştırması

Model	Model Karmaşıklığı	Çıkarım Hızı	Pratik Uygulanabilirlik
VGG16	Çok Yüksek	Düşük	Sunucu tabanlı sistemler
AlexNet	Yüksek	Orta	Kısıtlı kullanım
InceptionV3	Yüksek	Orta	Yüksek doğruluk gereken sistemler
MobileNetV2	Düşük	Yüksek	Mobil ve gömülü tarım uygulamaları
Özel CNN	Çok Düşük	Çok Yüksek	Gerçek zamanlı ve düşük donanımlı sistemler
VGG16	Çok Yüksek	Düşük	Sunucu tabanlı sistemler


Tablo 8’de, çalışmada kullanılan modellerin hesaplama maliyetleri ve pratik uygulanabilirlikleri karşılaştırılmıştır. InceptionV3 modeli en yüksek doğruluk oranını sağlamasına rağmen, daha karmaşık bir mimariye sahiptir. Buna karşılık, MobileNetV2 ve özel tasarlanmış CNN modeli, daha düşük hesaplama maliyetleri ve daha hızlı çıkarım süreleri sayesinde mobil cihazlar ve gömülü sistemler için daha uygun bir yapı sunmaktadır. Bu durum, model seçiminin yalnızca doğruluk değil, uygulama senaryosuna bağlı olarak hesaplama maliyeti açısından da değerlendirilmesi gerektiğini göstermektedir.



Şekil 6. MobileNetV2 Karmaşıklık Matrisi




Şekil 7. Özel CNN Karmaşıklık Matrisi



Şekil 8. InceptionV3 Karmaşıklık Matrisi



Şekil 9. AlexNet Karmaşıklık Matrisi



Şekil 10. VGG16 Karmaşıklık Matrisi

5. Sonuç ve Gelecek Çalışmalar (Conclusion and Future Work)

Bu çalışmada, bitki yaprak hastalıklarının sınıflandırılmasına yönelik olarak beş farklı derin öğrenme mimarisi karşılaştırılmıştır: VGG16, InceptionV3, AlexNet, MobileNetV2 ve özel olarak oluşturulan bir CNN modeli. Yapılan karşılaştırmalarda InceptionV3 modeli, tüm metriklerde (doğruluk, kayıp, precision, recall, F1 score) en yüksek başarıyı göstermiştir. Özellikle karmaşık yaprak hastalıklarını ayırt etme konusundaki başarısı, modelin çok ölçekli özellik çıkarımı yapabilme yeteneğinden kaynaklanmaktadır.

Özel CNN mimarisi de yüksek doğruluk oranları sunmuş, parametre sayısının daha düşük olması sayesinde hızlı çalışmasına rağmen güçlü sonuçlar üretmiştir. MobileNetV2'nin ise hafif bir mimari olmasına rağmen oldukça tatmin edici sonuçlar verdiği görülmüştür. Bu durum, modelin özellikle mobil tarım uygulamaları gibi kaynak sınırlı ortamlarda kullanımı için uygun bir aday olabileceğini göstermektedir.

Bununla birlikte, VGG16 ve AlexNet gibi daha klasik mimariler, modern modellere kıyasla bazı sınıflarda düşük performans göstermiştir. Bu durum, bu modellerin daha az katmanlı olması ve daha sınırlı öğrenme kapasitesiyle ilişkilendirilebilir.

Gelecek çalışmalarda, RGB görüntülere ek olarak hiperspektral görüntüleme verilerinin kullanılması ile yaprak hastalıklarının spektral özelliklerinin daha ayrıntılı analiz edilmesi hedeflenmektedir. Ayrıca, geliştirilen modellerin gerçek zamanlı tarla koşullarında kullanılabilmesi için mobil cihazlar ve gömülü sistemlere uygun hafif ve optimize edilmiş mimarilerin uygulanması planlanmaktadır. Bunun yanı sıra, farklı tarım alanlarından elde edilen verilerle federatif öğrenme yaklaşımlarının kullanılması, veri gizliliğinin korunarak modelin genelleme yeteneğinin artırılması açısından önemli bir araştırma konusu olarak değerlendirilmektedir.

Sonuç olarak, bu çalışma derin öğrenme tabanlı yöntemlerin tarımda hastalık tespiti gibi kritik bir alanda etkili ve uygulanabilir çözümler sunduğunu ortaya koymakta; araştırmacılar ve uygulayıcılar için model seçimi konusunda yol gösterici nitelik taşımaktadır. Ayrıca, gelecekte bu çalışmada kullanılan modellerin PlantVillage veri kümesi üzerinde de test edilerek literatürdeki mevcut çalışmalarla doğrudan karşılaştırılması planlanmaktadır.

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

Kaynaklar (References)

- [1] Kaggle Dataset. Plant Disease Recognition. Available: <https://www.kaggle.com/datasets/rashikrahmanpritom/plant-disease-recognition-dataset>. [Accessed: April 10, 2025].
- [2] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Frontiers in Plant Science*, vol. 7, article. 1419, 2016. doi:10.3389/fpls.2016.01419
- [3] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Computers and Electronics in Agriculture*, vol. 145, pp. 311-318, 2018. doi:10.1016/j.compag.2018.01.009
- [4] E. C. Too, L. Yujian, S. Njuki, and L. Yingchun, "A comparative study of fine-tuning deep learning models for plant disease identification," *Computers and Electronics in Agriculture*, vol. 161, pp. 272-279, 2019. doi:10.1016/j.compag.2018.03.032
- [5] G. Sreekumar, "Plant Leaf Disease Classification Using PyTorch," GitHub, Available: <https://github.com/GauthamSree/Plant-Leaf-Disease-Classification>, [Accessed: May 05, 2025].
- [6] J. Lu, J. Hu, G. Zhao, F. Mei, and C. Zhang, "Hyperspectral imaging and deep learning for identifying and classifying cucumber diseases," *Biosystems Engineering*, vol. 206, pp. 276-287, 2021. doi:10.1016/j.biosystemseng.2021.04.009
- [7] R. A. Harper, "Powdery Mildew," Available: <https://www.britannica.com/science/powdery-mildew>. [Accessed: April 15, 2025].
- [8] L. Perez and J. Wang, "The effectiveness of data augmentation in image classification using deep learning," *arXiv preprint arXiv:1712.04621*, 2017.
- [9] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?" in *Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 2*, 08 December 2014, pp 3320- 3328.
- [10] K. Simonyan & A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [11] M. Abu-Zanona, S. Elaiwaty, S. Younisz, N. Innabx, and M. M. Kamruzzaman, "Classification of Palm Trees Diseases using Convolution Neural Network," *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 6, pp. 1-7, 2022, doi: 10.14569/IJACSA.2022.01306111
- [12] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 27-30 June 2016, pp. 2818-2826.
- [13] Y. Zhang, N. R. Werf, B. Jiang, R. Hamersvelt, M. J. W. Greuter, and X. Xie, "Motion-corrected coronary calcium scores by a convolutional neural network: a robotic simulating study," *European Radiology*, vol. 30, no. 10, pp. 1285-1294, 2019. doi: 10.1007/s00330-019-06447-7
- [14] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Advances in Neural Information Processing Systems*, vol. 25, pp. 1097-1105, 2012.
- [15] S. Bangar, "AlexNet Architecture Explained," Jun 24, 2022, Available: <https://medium.com/@siddheshb008/alexnet-architecture-explained-b6240c528bd5>, [Accessed: May. 12, 2025].
- [16] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, UT, USA, 18-23 June 2018, pp. 4510-4520.
- [17] K. C. Martinez, J. A. R. Rodriguez, J. G. R. Hernandez, and R. S. V. Mercado "Implementación De Una Inteligencia Artificial Para La Interpretación De La Prueba Proyectiva "Machover" Basada En Redes Neuronales Artificiales," *Revista Digital de Tecnologías Informáticas y Sistemas*, vol. 7, no. 1, pp. 85-92, 2023. doi.org/10.61530/redtis.vol7.n1.2023.139.86-93
- [18] A. A. Salman, R. A. Mustapha, M. A. Basri, and M. A. S. Kamal, "Classification of tomato leaf diseases using deep convolutional neural network," *IEEE Access*, vol. 9, pp. 143115-143123, 2021.
- [19] B. Bisong, *Google Colaboratory*, in *Building Machine Learning and Deep Learning Models on Google Cloud Platform*, Berkeley, CA: Apress, 2019, pp. 59-64. https://doi.org/10.1007/978-1-4842-4470-8_6
- [20] D. M. W. Powers, "Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation," *J. Mach. Learn. Technol.*, vol. 2, no. 1, pp. 37-63, 2011.
- [21] S. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, vol. 45, no. 4, pp. 427-437, 2009. doi:10.1016/j.ipm.2009.03.002

