Black Sea Journal of Engineering and Science
doi: 10.34248/bsengineering.1974532

Open Access Journal
e-ISSN: 2619 – 8991

Araştırma Makalesi (Research Article)
Cilt 9 - Sayı 5: 2281-2287 / Eylül 2026
(Volume 9 - Issue 5: 2281-2287 / September 2026)

# SÜRDÜRÜLEBİLİR TARIMDA HAFİF DERİN ÖĞRENME VE HİBRİT MAKİNE ÖĞRENMESİ YAKLAŞIMLARI İLE OPTİMİZE EDİLMİŞ YAPRAK HASTALIĞI TESPİTİ

**Hasan Hüseyin ÇELİK[1]***

[1]*Marmara University, Faculty of Technology, Department of Electrical and Electronics Engineering, 34854, Istanbul, Türkiye*

**Özet:** Küresel iklim değişikliği ve nüfus artışı, tarımsal üretimde sürdürülebilirliği ve gıda arzı güvenliğini kritik bir boyuta taşımıştır. Bitki ve mahsul yapraklarında meydana gelen hastalıklar, rekolte miktarını ve gıda kalitesini doğrudan tehdit eden temel unsurların başında gelmektedir. Geleneksel hastalık teşhis yöntemleri insan hatasına açık, maliyetli ve zaman alıcıdır. Son yıllarda derin öğrenme tabanlı evrişimli sinir ağları (CNN) bu problemin çözümünde yüksek başarım göstermiş olsa da, bu modellerin uçtan uca (end-to-end) eğitimi ve çalıştırılması yüksek hesaplama gücü (GPU) ve uzun işlem süreleri gerektirmektedir. Bu durum, internet ve gelişmiş donanım altyapısının kısıtlı olduğu kırsal tarım alanlarında akıllı sistemlerin kullanımını zorlaştırmaktadır. Bu çalışmada, düşük hesaplama maliyetine sahip ve bilgisayar işlemcisi (CPU) kullanan, hiperparametre optimizasyonlu hibrit bir yapay zeka mimarisi önerilmiştir. Önerilen yöntemde, ImageNet veri seti ile önceden eğitilmiş MobileNetV2 mimarisi sadece bir öznitelik çıkarıcı (feature extractor) olarak kullanılmış ve görüntüler 1280 boyutlu sayısal vektörlere indirgenmiştir. Elde edilen öznitelikler, 3-katlamalı çapraz doğrulama (3-Fold Cross-Validation) destekli Izgara Araması (GridSearchCV) ile optimize edilen Destek Vektör Makineleri (SVM), Rastgele Orman (RF) ve XGBoost algoritmaları ile sınıflandırılmıştır. Bu işlemler ayrıca MobileNetV3 mimarisi ile tekrarlanmıştır. Deneysel sonuçlar, önerilen MobileNetV3+SVM hibrit modelinin minimum işlem zamanı ve donanım kaynağı ile yüksek bir sınıflandırma başarımı sunduğunu göstermiştir. Geliştirilen hafif mimari, tarımsal alanlarda mobil ve uç bilişim cihazlarına entegre edilebilir bir potansiyele sahiptir.

**Anahtar kelimeler:** Akıllı tarım, Derin öznitelik çıkarımı, Hibrit modeller, Hiperparametre optimizasyonu

## Optimized Leaf Disease Detection in Sustainable Agriculture Using Lightweight Deep Learning and Hybrid Machine Learning Approaches

**Abstract:** Global climate change and population growth have made sustainability in agricultural production and food supply security critical. Diseases affecting plant and crop leaves are among the primary factors directly threatening yield and food quality. Traditional disease diagnosis methods are prone to human error, costly, and time-consuming. Although deep learning-based convolutional neural networks (CNNs) have shown high performance in solving this problem in recent years, end-to-end training and execution of these models require high computational power (GPU) and long processing times. This makes the use of intelligent systems difficult in rural agricultural areas where internet and advanced hardware infrastructure are limited. In this study, a hybrid artificial intelligence architecture with low computational cost, CPU usage, and hyperparameter optimization is proposed. In the proposed method, the MobileNetV2 architecture, pre-trained with the ImageNet dataset, is used only as a feature extractor, and the images are reduced to 1280-dimensional digital vectors. The obtained features were classified using Support Vector Machines (SVM), Random Forest (RF), and XGBoost algorithms optimized with GridSearchCV supported by 3-Fold Cross-Validation. These processes were also repeated with the MobileNetV3 architecture. Experimental results showed that the proposed MobileNetV3+SVM hybrid model offers high classification performance with minimum processing time and hardware resources. The developed lightweight architecture has the potential to be integrated into mobile and edge computing devices in agricultural settings.

**Keywords:** Smart agriculture, Deep feature extraction, Hybrid models, Hyperparameter optimization

***Sorumlu yazar (Corresponding author):** Marmara University, University, Faculty of Technology, Department of Electrical and Electronics Engineering, 34854, Istanbul, Türkiye
**E mail:** hcelik@marmara.edu.tr (H. H. ÇELİK)
Hasan Hüseyin ÇELİK https://orcid.org/0000-0003-2885-0501

**Gönderi:** 19 Haziran 2026 **Received:** June 19, 2026
**Kabul:** 30 Temmuz 2026 **Accepted:** July 30, 2026
**Yayınlanma:** 15 Eylül 2026 **Published:** September 15, 2026

**Cite as:** Çelik, H. H. (2026). Optimized leaf disease detection in sustainable agriculture using lightweight deep learning and hybrid machine learning approaches. *Black Sea Journal of Engineering and Science,* 9(5), 2281-2287.

## 1. Giriş

Küresel gıda talebinin hızla arttığı günümüzde, tarımsal üretim alanlarının korunması ve birim alandan alınan verimin artırılması sürdürülebilir kalkınma hedeflerinin merkezinde yer almaktadır. Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) verilerine göre, dünyada her yıl tarımsal mahsullerin önemli bir yüzdesi hastalık ve zararlılar nedeniyle hasat edilemeden kaybedilmekte ve bu durum küresel gıda krizini tetiklemektedir (FAO, 2024). Bu kayıpların erken evrede tespit edilmesi, kimyasal ilaç kullanımının optimize edilmesi ve ürün kayıplarının en aza indirilmesi açısından hayati önem



This work is licensed (CC BY-NC 4.0) under Creative Commons Attribution 4.0 International License

taşımaktadır. Geleneksel tarımda hastalık tespiti, uzman ziraat mühendislerinin veya çiftçilerin fiziksel gözlemlerine dayanmaktadır. Geniş tarım arazilerinde bu süreç hem lojistik olarak zor hem de subjektif yorumlamalara bağlı olarak hata payı yüksek bir yaklaşımdır (Patel, M. vd., 2024).

Endüstri 4.0 ve Hassas Tarım vizyonu, yapay zeka ve bilgisayarlı görü (computer vision) tekniklerinin tarımsal süreçlere entegrasyonunu hızlandırmıştır. Özellikle Evrişimli Sinir Ağları (CNN), bitki yaprak görüntülerindeki morfolojik değişimleri ve hastalık lekelerini insan gözünden daha hassas bir şekilde analiz edebilmektedir (SinghDhaka vd., 2023). Literatürde yer alan güncel çalışmalarda, ağır derin öğrenme mimarilerinin bitki hastalıklarının sınıflandırılmasında %95'in üzerinde doğruluk oranlarına ulaştığı görülmektedir (Thakur vd., 2024). Ancak bu modeller uçtan uca eğitildiklerinde milyonlarca eğitilebilir parametreye sahip olmaları sebebiyle devasa grafik işlem birimlerine (GPU) ihtiyaç duymakta ve eğitim süreçleri saatler sürmektedir. Ayrıca, model boyutlarının büyük olması bu sistemlerin tarım sahalarında kullanılan insansız hava araçları (İHA) veya kısıtlı donanıma sahip mobil cihazlar üzerinde gerçek zamanlı çalışmasını zorlaştırmaktadır (Savaş, 2024).

Bu çalışmanın temel amacı; yüksek hesaplama gücü ve uzun eğitim süreleri gerektiren geleneksel derin öğrenme yaklaşımlarına alternatif olarak, kaynak tasarrufu sağlayan (Green AI) hibrit bir mimari geliştirmektir. Çalışma kapsamında, hafifliği ve mobil uyumluluğu ile bilinen MobileNetV2 ve MobileNetV3 mimarileri öznitelik çıkarıcı olarak konumlandırılmış, sınıflandırma yükü ise klasik makine öğrenmesi algoritmalarına devredilmiştir (Savaş, 2024). Rastgele parametre seçiminin önüne geçmek amacıyla sınıflandırıcı aşamasında 3-katlamalı Izgara Araması (GridSearchCV) ile sistematik bir hiperparametre optimizasyonu gerçekleştirilmiştir. Böylece, literatürdeki ağır modellere kıyasla bilgisayar işlemcisi (CPU) üzerinde saniyeler içinde optimize olabilen, doğruluktan ödün vermeyen ve uç cihazlara entegrasyona hazır güncel bir kombinasyon sunulmuştur.

## 2. Materyal ve Yöntem

### 2.1. Deneysel Veri Seti

Bu çalışmada, literatürde sıklıkla referans gösterilen ve açık erişimli olarak sunulan akademik PlantVillage veri seti kullanılmıştır (Hughes ve Salathé, 2015). Türkiye tarımındaki önceliği ve kısıtlı zaman diliminde çözümleme göz önüne alınarak, veri setinden örnek olarak domates mahsulüne ait yaprak görüntüleri alınmıştır. Yaprak görüntüleri yetiştirme aşamasındaki domateslerin sağlık durumlarını yansıtmaktadır. Veri setinden RS ve GH genetik kodları ile bilinen domateslere ait sağlıklı, erken yanıklık ve geç yanıklık durumlarını temsil eden kümelerden dengeli 1000 adet kayıt seçilmiştir. Sağlıklı, erken yanıklık ve geç yanıklık örnekleri Şekil 1'de görülmektedir.

Deneysel süreçte sınıflar arasında oluşabilecek veri dengesizliği probleminin ve yanlılığın önüne geçebilmek amacıyla veri seti elle bölünmemiş, tabakalı rastgele bölme mimarisiyle kod seviyesinde ayrıştırılmıştır.

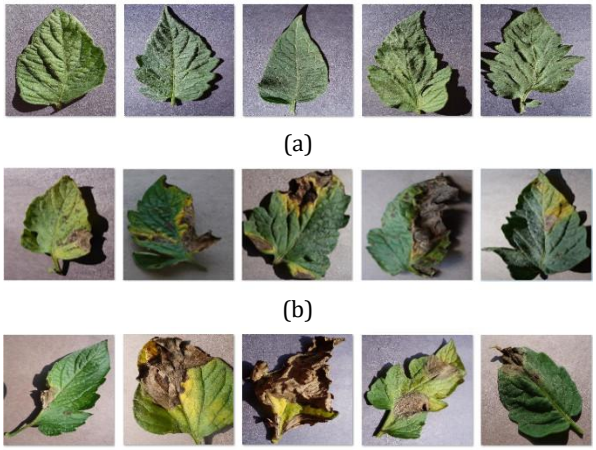

(a) (b) (c)

**Şekil1.** Domates yapraklarına ait örnek resimler, a) Sağlıklı, b) Erken yanıklık, c) Geç yanıklık.

Toplam 3000 kayıttan oluşan veri seti, her bir sınıfa ait ana dağılım oranları tam olarak korunarak %80 eğitim (2400 örnek) ve %20 doğrulama (600 örnek) olacak şekilde bağımsız alt kümelere otomatik olarak transfer edilmiştir. Bu sayede modellerin eğitimi esnasında herhangi bir sınıfa yönelik aşırı öğrenme veya eksik öğrenme riski matematiksel olarak elimine edilmiştir. Sınıfların dağılımı ve örnek sayılarına ilişkin detaylar Tablo 1'de sunulmuştur.

**Tablo 1.** Kullanılan veri setine ait sınıf dağılımları

| Bitki türü / sağlık durumu | Eğitim örnek sayısı | Doğrulama örnek sayısı | Toplam |
|---|---|---|---|
| Sınıf 1 - Domates Sağlıklı | 800 | 200 | 1000 |
| Sınıf 2 - Domates Erken Yanıklık | 800 | 200 | 1000 |
| Sınıf 3 - Domates Geç Yanıklık | 800 | 200 | 1000 |
| Toplam | 2400 | 600 | 3000 |

### 2.2. Veri Ön İşleme ve Derin Öznitelik Çıkarımı

Bu çalışmada görüntülerin modele homojen bir şekilde beslenmesi amacıyla tüm yaprak resimleri 224×224 piksel boyutuna yeniden ölçeklenmiştir. Ardından, önceden eğitilmiş modelin ağırlıklarıyla uyumluluk sağlaması için ImageNet veri setinin kanal ortalamaları $\mu=[0.485,0.456,0.406]$ ve standart sapmaları $\sigma=[0.229,0.224,0.225]$ kullanılarak RGB kanalları üzerinde normalizasyon işlemi uygulanmıştır.

Öznitelik çıkarma aşamasında, derin ayrılabilir evrişim mimarisi sayesinde standart evrişim katmanlarına göre

parametre sayısını ve işlem hacmini büyük ölçüde azaltan MobileNetV2 modeli tercih edilmiştir (Sandler vd., 2018). Ayrıca bu işlem, performanslarını kıyaslamak amacıyla MobileNetV3 modeli ile tekrarlanmıştır. Modelin ImageNet üzerinde eğitilmiş olan ağırlıkları dondurulmuş ve ağın en sonunda yer alan sınıflandırma katmanı devredışı bırakılarak yerine etkisiz bir katman yerleştirilmiştir. Bu sayede, her bir yaprak görüntüsü ön işleme katmanlarından geçtikten sonra MobileNetV2 ve MobileNetV3'ün küresel ortalama havuzlama katmanından çıkarak 1 ×1280 boyutunda ayırt edici birer öznitelik vektörüne dönüştürülmüştür. Bu işlem ile uzamsal görüntü verileri, klasik makine öğrenmesinin işleyebileceği yüksek nitelikli tablo verilerine indirgenmiştir.

### 2.3. Hibrit Sınıflandırma ve Hiperparametre Optimizasyonu

Kullanılan derin ağdan elde edilen 1280 boyutlu öznitelik vektörleri, üç farklı matematiksel sınıflandırıcıya girdi olarak verilmiştir. Bu sınıflandırıcılar Destek Vektör Makineleri (SVM), Rastgele Orman (Random Forest) ve XGBoost modelleridir (Cortes ve Vapnik, 1995; Breiman, 2001). Algoritmaların varsayılan parametrelerle çalıştırılması yerine, en yüksek genelleyici performansa ulaşmak adına Izgara Araması (GridSearchCV) yöntemi uygulanmıştır. Optimizasyon süreci, veri kümesinin küçük parçalarındaki varyasyonları da yakalayabilmek için 3-katlamalı çapraz doğrulama ile desteklenmiştir.

SVM için ceza parametresi C ∈\{0.1,1,10}, çekirdek tipi kernel ∈ {linear,rbf} ve gama parametresi γ ∈ {scale,auto} kombinasyonları taranmıştır. RF için ise karar ağacı sayısı n_estimators ∈ {50,100} ve maksimum derinlik sınırları incelenmiştir. Tüm bu deneysel süreç, önerilen yöntemin donanım bağımsızlığını kanıtlamak amacıyla herhangi bir grafik işlemci (GPU) kullanılmadan, standart bir bilgisayar işlemcisi (CPU) üzerinde gerçekleştirilmiştir.

Modellerin başarım analizinde Doğruluk, Kesinlik, Duyarlılık ve F1-Skor standart metrikleri kullanılmıştır. Metriklerin matematiksel ifadeleri eşitlik 1, 2, 3 ve 4'te verilmiştir.

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

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

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

$$\text{F1-Skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

## 3. Bulgular

### 3.1. Hiperparametre Optimizasyonu ve Zaman Performansı Bulguları

Izgara araması sonucunda, veri seti için en optimal parametre kombinasyonları belirlenmiştir. MobileNetV2 ve MobileNetV3 öznitelikleriyle çalışan SVM modeli için en iyi başarım doğrusal çekirdek kernel='linear' ve C=10 parametrelerinde elde edilmiştir. Rastgele Orman ve XGBoost modelleri için ise n_estimators=100 kombinasyonu en kararlı sonucu üretmiştir.

CPU üzerinde gerçekleştirilen optimizasyon ve eğitim süreçlerine ait zaman maliyetleri Tablo 2'de paylaşılmıştır.

Tablo 2 incelendiğinde, derin öğrenme modellerinin günlerce süren uçtan uca eğitim sürelerine kıyasla, önerilen hibrit yöntemin saniyeler mertebesinde eğitimi tamamladığı görülmektedir. Bu durum, modelin CPU üzerinde dahi ne kadar hızlı optimize olabilen düşük maliyetli bir yapı sunduğunun somut bir göstergesidir.

**Tablo 2.** Önerilen hibrit modellerin eğitim süresi ve genel başarım karşılaştırması

| Önerilen hibrit model yapısı | Optimizasyon ve eğitim süresi (s) | En iyi parametre seti | Genel doğruluk |
|---|---|---|---|
| MobileNetV2+SVM | 65,8 | "{'C': 10, 'gamma': 'scale', 'kernel': 'rbf'}" | %96,3 |
| MobileNetV2+RF | 13,17 | "{'max_depth': 20, 'n_estimators': 100}" | %91,6 |
| MobileNetV2+XGBoost | 351,2 | "{'learning_rate': 0.1, 'max_depth': 3, 'n_estimators': 100}" | %93,6 |
| MobileNetV3+SVM | 32,19 | "{'C': 10, 'gamma': 'scale', 'kernel': 'rbf'}" | %99,0 |
| MobileNetV3+RF | 55,47 | "{'max_depth': 10, 'n_estimators': 100}" | %93,6 |
| MobileNetV3+XGBoost | 149,8 | "{'learning_rate': 0.1 'max_depth': 3, 'n_estimators': 100}" | %94,8 |

### 3.2. Sınıf Bazlı Performans ve Hata Matrisi Analizi

Önerilen hibrit model yaklaşımını değerlendirmek amacıyla, MobileNetV2 ve MobileNetV3 ile birlikte SVM, RF ve XGBoost sınıflandırıcıları kullanılarak hibrit modeller oluşturulmuştur. Hibrit modellerin sınıf bazlı performanslarını karşılaştırmak amacıyla bunlara ait karışıklık matrisleri üretilmiştir. MobileNetV2 mimarisi ile üretilen hibrit modellerin hata matrisleri Şekil 2'de, MobileNetV3 ile üretilenler ise Şekil 3'de görülmektedir.

Rastgele Orman (RF) algoritmasının, yapısı gereği öznitelik uzayındaki korelasyonları alt ağaçlara bölerken Domates Geç Yanıklık sınıfında SVM'e kıyasla %12.5 oranında daha fazla yanılma yaşadığı görülmüştür. SVM modeli ise doğrusal ayrıştırıcı avantajı sayesinde yaprak üzerindeki erken evre lezyon benzerliklerini daha kararlı

ayırt etmiş ve diyagonal hattaki doğru tahmin yoğunluğunu korumuştur.

Önerilen modellerin sınıflara göre gösterdiği detaylı performans metrikleri çıkartılmıştır. MobileNetV2 mimarisi için üretilen performans metrikleri Tablo 3'de, MobileNetV3 mimarisi için üretilenler ise Tablo 4'de toplu halde gösterilmiştir. Tablo verilerinden görüldüğü gibi, optimize edilmiş MobileNetV2+SVM ve MobileNetV3+SVM modelleri en yüksek doğruluğu üretmektedir. Modelin test aşamasında ürettiği hata matrisi incelendiğinde, sınıfların büyük oranda doğru tahmin edildiği gözlemlenmiştir. Belirli sınıflar arasındaki çok küçük sapmaların morfolojik nedeni araştırıldığında, lezyonların erken evrede yaprak üzerinde bıraktığı nekrotik lekelerin birbirine yapısal olarak çok benzediği tespit edilmiştir (Thakur vd., 2024).

### 3.3. Çıkarım Hızı ve Literatür Tartışması

Modellerin gerçek zamanlı tarımsal sahalardaki pratik uygulanabilirliğini test etmek amacıyla, oluşturulan hibrit modellerin tek bir görüntü için karar verme süreleri hesaplanmıştır. Bu işlemler, 2.4GHz 64bit Intel i5 işlemci ve 16MB bellek özelliklerine sahip bir bilgisayar kullanılarak Python 3.14.5 program ortamında gerçekleştirilmiştir. Tek bir yaprak görüntüsünün, analiz ve sınıflandırma aşamaları için hesaplanan çıkarım süreleri ve genel doğruluk oranları Tablo 5'de verilmiştir. Tablo 5'e göre SVM algoritması, RF ve XGBoost algoritmalarına kıyasla daha yüksek doğruluk oranları üretmektedir. Ayrıca daha kısa çıkarım süreleri sağlamaktadır. Bu fark, SVM algoritmasının doğrusal karar sınırlarını matematiksel olarak daha hızlı filtrelemesinden kaynaklanmaktadır.

Yapılan testlerde, MobileNetV3 mimarisinin MobileNetV2'ye göre daha kısa çıkarım sürelerine ulaştığı görülmektedir. Bunun temel nedenleri, MobileNetV3'ün donanım odaklı ağ mimarisi optimizasyonu, üstel aktivasyon fonksiyonları gibi ağır hesaplama yüküne sahip işlemleri azaltacak şekilde yeniden tasarlanmış bir mimariye sahip olmasıdır.

Bu sonuçlar, MobileNetV2+SVM ve MobileNetV3+SVM hibrit yapılarının uç bilişim cihazlarında yüksek frekanslı gerçek zamanlı çalışmaya tamamen uygun olduğunu göstermektedir.

Literatürde yer alan ve benzer veri setlerini kullanan güncel ağır CNN çalışmaları incelendiğinde (SinghDhaka vd., 2023; Thakur vd., 2024), bu modellerin yüksek başarım oranlarına ulaşmasına rağmen model boyutlarının yüzlerce megabayta dayandığı ve CPU üzerindeki çıkarım sürelerinin oldukça hantallaştığı bilinmektedir. Önerilen hibrit model ise hem düşük bellek tüketimi hem de çok kısa sürelerde (21,1ms) karar üretebilmesi yönüyle öne çıkmaktadır. Bu durum, önerilen yöntemin tarım arazilerinde internete ve bulut sunuculara ihtiyaç duymadan, uç bilişim cihazlarında gerçek zamanlı olarak çalışabileceğini doğrulamaktadır (Patel, M. vd., 2024).

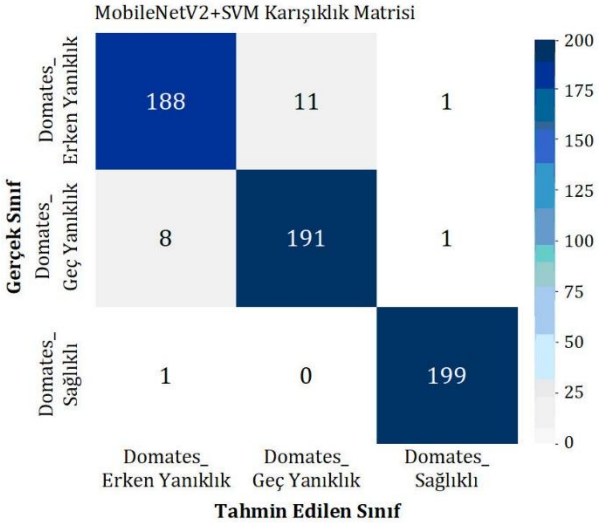


(a)

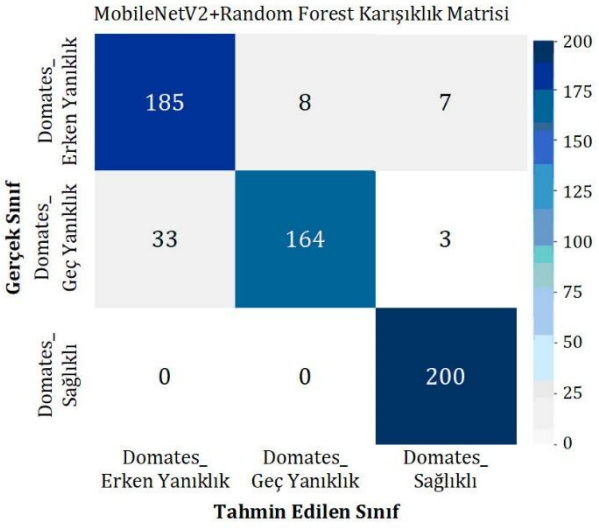


(b)

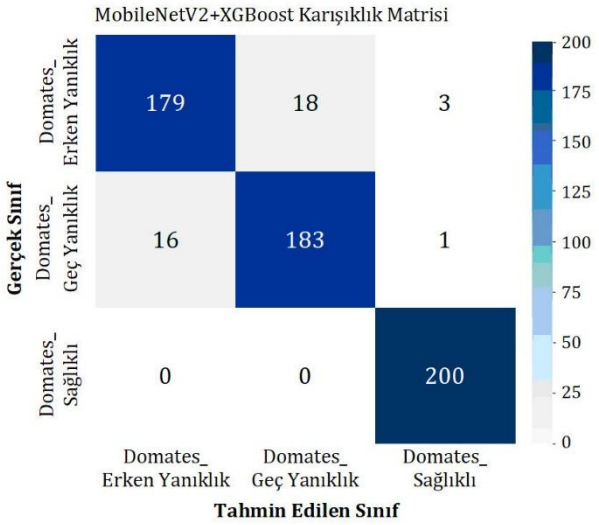


(c)

**Şekil 2.** (a) MobileNetV2+SVM karışıklık matrisi, (b) MobileNetV2+RF karışıklık matrisi, (c) MobileNetV2+XGBoost karışıklık matrisi.

,

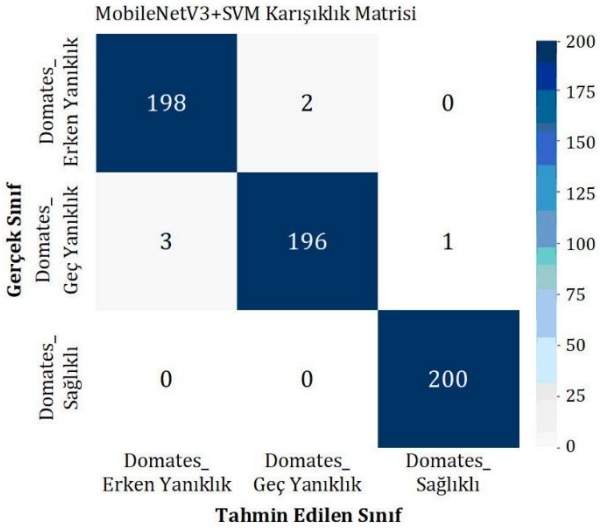


(a)

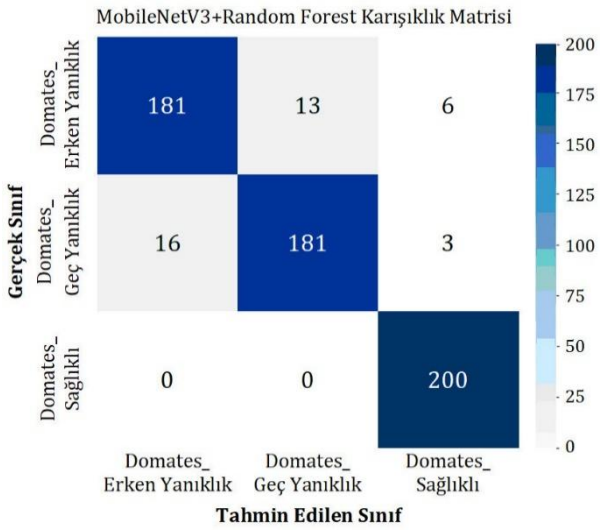


(b)

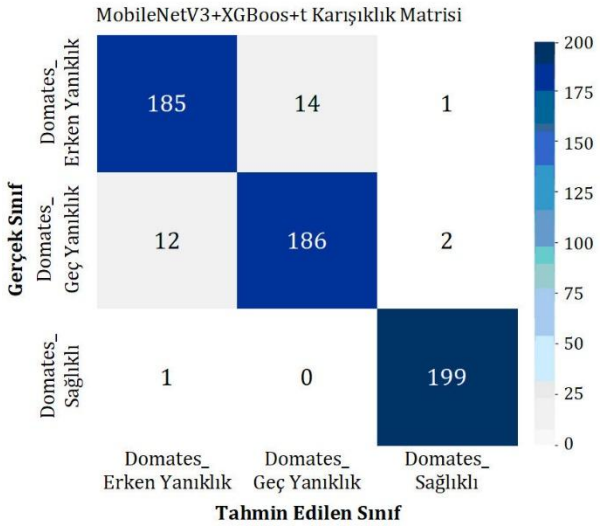


(c)

**Şekil 3.** (a) MobileNetV3+SVM karışıklık matrisi, (b) MobileNetV3+RF karışıklık matrisi, (c) MobileNetV3+XGBoost karışıklık matrisi.

## 4. Tartışma ve Sonuç

Bu çalışmada, tarımsal üretimde büyük ekonomik kayıplara yol açan yaprak hastalıklarının tespiti için donanım maliyetini minimize eden, hızlı ve yüksek başarımlı hibrit bir yapay zeka yaklaşımı sunulmuştur. Geliştirilen mimaride, MobileNetV2 ve MobileNetV3 ortamlarından sağlanan derin öğrenmenin güçlü görsel anlamlandırma yeteneği ile klasik makine öğrenmesinin (SVM) optimize edilmiş karar sınırları bir araya getirilmiştir.

Elde edilen deneysel sonuçlar, çapraz doğrulama destekli ızgara araması ile optimize edilen hibrit modelin, GPU altyapısına ihtiyaç duymadan, standart bir CPU üzerinde dahi yüksek doğruluk oranlarına ve milisaniyeler seviyesinde çıkarım sürelerine ulaşabildiğini kanıtlamıştır. Gelecek çalışmalarda, önerilen bu hafif hibrit yapının mobil çiftçi uygulamalarına veya otonom drone sistemlerine entegre edilerek canlı hastalık haritalandırma çalışmalarında kullanılması planlanmaktadır.

**Tablo 3.** Optimize edilmiş MobileNetV2 ile SVM, RF ve XGBoost modellerinin sınıf bazlı detaylı performansları

| | Kesinlik | | | Duyarlılık | | | F1-Skor | | |
|---|---|---|---|---|---|---|---|---|---|
| Sınıf Adı | SVM | RF | XGBoost | SVM | RF | XGBoost | SVM | RF | XGBoost |
| Sınıf 1 - Domates Sağlıklı | %99,0 | %96,1 | %92 | %99,5 | %100 | %90 | %99,2 | %98,0 | %91 |
| Sınıf 2 - Domates Erken Yanıklık | %95,4 | %85,0 | %91 | %94,0 | %91,0 | %92 | %94,7 | %87,9 | %91 |
| Sınıf 3 - Domates Geç Yanıklık | %94,5 | %93,2 | %98 | %95,5 | %83,0 | %100 | %95,0 | %87,8 | %99 |
| Makro Ortalama | %96,3 | %91,4 | %94 | %96,3 | %91,3 | %94 | %96,3 | %91,2 | %94 |

**Tablo 4.** Optimize edilmiş MobileNetV3 ile SVM, RF ve XGBoost modellerinin sınıf bazlı detaylı performansları

| | Kesinlik | | | Duyarlılık | | | F1-Skor | | |
|---|---|---|---|---|---|---|---|---|---|
| Sınıf Adı | SVM | RF | XGBoost | SVM | RF | XGBoost | SVM | RF | XGBoost |
| Sınıf 1 - Domates Sağlıklı | %99 | %92 | %93 | %99 | %91 | %93 | %99 | %91 | %93 |
| Sınıf 2 - Domates Erken Yanıklık | %99 | %93 | %93 | %98 | %91 | %93 | %98 | %92 | %93 |
| Sınıf 3 - Domates Geç Yanıklık | %100 | %96 | %99 | %100 | %100 | %99 | %100 | %98 | %99 |
| Makro Ortalama | %99 | %94 | %95 | %99 | %94 | %95 | %99 | %94 | %95 |

**Tablo 5.** Önerilen hibrit modellerin çıkarım hızları ve doğruluk karşılaştırması

| Hibrit model mimarisi | Genel doğruluk | Tekil resim çıkarım süresi (ms) |
|---|---|---|
| MobileNetV2+SVM | %96,3 | 35,11 |
| MobileNetV2+RF | %91,6 | 44,35 |
| MobileNetV2+XGBoost | %93,6 | 35,36 |
| MobileNetV3+SVM | %99,0 | 21,51 |
| MobileNetV3+RF | %93,6 | 33,0 |
| MobileNetV3+XGBoost | %94,8 | 22,10 |

**Katkı Oranı Beyanı**

Yazarın katkı yüzdeleri aşağıda verilmiştir. Yazar makaleyi incelemiş ve onaylamıştır.

| | H.H.Ç. |
|---|---|
| K | 100 |
| T | 100 |
| Y | 100 |
| VTI | 100 |
| VAY | 100 |
| KT | 100 |
| YZ | 100 |
| KI | 100 |
| GR | 100 |
| PY | 100 |
| FA | 100 |

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi, FA= fon alımı.

**Çatışma Beyanı**

Yazar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

**Etik Onay Beyanı**

Bu araştırmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

**Destek ve Teşekkür Beyanı**

Bu çalışmayı destekleyen ve rehberlik sağlayan Marmara Üniversitesi Mühendislik Fakültesi Öğretim Üyesi Prof. Dr. Cabir VURAL'a teşekkürlerimi sunarım.

## Kaynaklar

Breiman, L. (2001). Random forests. *Machine Learning*, *45*(1), 5–32. https://doi.org/10.1023/A:1010933404324

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning, 20*(3), 273–297. https://doi.org/10.1007/bf00994018

Food and Agriculture Organization of the United Nations. (2024). *The state of food and agriculture 2024: Moving forward on agrifood systems transformation*. https://doi.org/10.4060/cd2431en

Hughes, D. P., & 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.

Patel, M., Tanwar, S., Jindal, A., Alshammari, N., Pervaiz, H., & Ahmed, H. (2024). A blockchain-based predictive maintenance scheme for smart agriculture. In *2024 IEEE/ACM 17th International Conference on Utility and Cloud Computing (UCC)* (pp. 405–410). IEEE.

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4510–4520). IEEE.

Savaş, S. (2024). Application of deep ensemble learning for palm disease detection in smart agriculture. *Heliyon, 10*(17), Article e37141. https://doi.org/10.1016/j.heliyon.2024.e37141

SinghDhaka, V., Kundu, N., Rani, G., Zumpano, E., & Vocaturo, E. (2023). Role of Internet of Things and deep learning techniques in plant disease detection and classification: A focused review. *Sensors, 23*(18), Article 7877. https://doi.org/10.3390/s23187877

Thakur, A., Sharma, S., & Thapar, P. (2024). A comprehensive review of plant disease detection and analysis using machine learning techniques. In *2024 7th International Conference on Contemporary Computing and Informatics (IC3I)*. IEEE.