



GÖRÜNTÜ ÖN İŞLEME TEKNİKLERİ VE DERİN ÖĞRENME İLE BİTKİ ZARARLILARININ SINIFLANDIRILMASI

Şevval Ezgi EZE¹, Selcan KAPLAN BERKAYA^{1*}

¹Eskişehir Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir, Türkiye

Anahtar Kelimeler	Öz
<i>Derin Öğrenme, Transfer Öğrenimi, Görüntü Ön İşleme, Bitki Zararlısı Sınıflandırma, Akıllı Tarım.</i>	Bitki zararlılarının erken dönemde, etkili bir şekilde tespit edilip kontrol altına alınmalarını sağlamak bitkilerin korunmasına, ürün veriminin artırılmasına ve tarım ekonomisindeki kayıpların azaltılmasına yardımcı olmaktadır. Bu çalışmada, bitki zararlılarının sınıflandırılması için derin öğrenme tabanlı yöntemler önerilmiştir. Aynı zamanda farklı görüntü ön işleme tekniklerinin performansa etkisi araştırılmıştır. Önerilen modeller, önceden eğitilmiş beş farklı derin sinir ağı (GoogLeNet, ResNet-18, ResNet-101, VGG-16 ve VGG-19) ile transfer öğrenimi ve bu ağlardan çıkarılan öznetelikler ile Destek Vektör Makinesi sınıflandırıcısını kullanmaktadır. Ayrıca yeşil renk kanalı çıkarımı, veri artırımı, histogram eşitleme, derin öğrenme tabanlı segmentasyon ile arka plan eliminasyonu gibi farklı görüntü ön işleme teknikleri ayrı ayrı ve birlikte kullanılarak kapsamlı bir performans analizi yapılmıştır. Deneyler, sırasıyla 10 ve 40 bitki zararlısı türü içeren Li ve D0 veri setleri üzerinde gerçekleştirilmiştir. Deneyler sonucunda iki veri setinde de veri artırımı ve ResNet-101 ağı ile transfer öğrenimi yöntemi kullanılarak sırasıyla %96.36 ve %99.63 doğruluk ile en yüksek performanslar elde edilmiştir. Deneysel sonuçlar, önerilen modellerin bitki zararlısı kontrolünde etkin bir şekilde kullanılabileceğini göstermektedir.

CLASSIFICATION OF INSECT PESTS WITH DEEP LEARNING AND IMAGE PREPROCESSING TECHNIQUES

Keywords	Abstract
<i>Deep Learning, Transfer Learning, Image Processing, Insect Pest Classification, Smart Agriculture.</i>	Early and effective insect pest detection and control help to protect plants, increase crop yields, and reduce losses in the agricultural economy. In this paper, deep learning-based methods are proposed for classifying insect pests. Additionally, the impact of various image preprocessing techniques on performance has been investigated. The proposed models utilize transfer learning with five different pre-trained deep neural networks (GoogLeNet, ResNet-18, ResNet-101, VGG-16, and VGG-19), and Support Vector Machine classifier with features extracted from these networks. Furthermore, a comprehensive performance analysis is conducted using various image preprocessing techniques such as green color channel extraction, data augmentation, histogram equalization, and background elimination with deep learning based segmentation, individually and in combination. The experiments were conducted on the Li and D0 datasets containing 10 and 40 insect pest species, respectively. As a result of the experiments, the highest performances were obtained on both datasets, with accuracy rates of 96.36% and 99.63%, respectively, using data augmentation and transfer learning with the ResNet-101 network. The experimental results indicate that the proposed models can be effectively used in insect pest control.

Alıntı / Cite

Eze, Ş. E., Kaplan Berkaya, S., (2024). Görüntü Ön İşleme Teknikleri ve Derin Öğrenme ile Bitki Zararlılarının Sınıflandırılması. Mühendislik Bilimleri ve Tasarım Dergisi, 12(2), 455-465.

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process
Şevval Ezgi EZE, 0009-0005-3193-592X	Başvuru Tarihi / Submission Date 26.05.2024
Selcan KAPLAN BERKAYA, 0000-0001-6728-4050	Revizyon Tarihi / Revision Date 06.06.2024
	Kabul Tarihi / Accepted Date 12.06.2024
	Yayın Tarihi / Published Date 30.06.2024

* İlgili yazar / Corresponding author: skb@eskisehir.edu.tr, +90-222-213-8110

CLASSIFICATION OF INSECT PESTS WITH DEEP LEARNING AND IMAGE PREPROCESSING TECHNIQUES

Şevval Ezgi EZE, Selcan KAPLAN BERKAYA^{1†}

¹ Eskisehir Technical University, Faculty of Engineering, Department of Computer Engineering, Eskisehir, Turkiye

Highlights

- Deep learning-based models are proposed for insect pest classification.
- The impact of various image preprocessing techniques on performance has been investigated.
- Experiments on two datasets showed that the proposed models are effective for insect pest control.

Purpose and Scope

Early and effective insect pest detection and control help to protect plants, increase crop yields, and reduce losses in the agricultural economy. In this paper, deep learning-based methods are proposed for classifying insect pests. Additionally, the impact of various image preprocessing techniques on performance has been investigated.

Design/methodology/approach

The proposed models utilize transfer learning with five different pre-trained deep neural networks (GoogLeNet, ResNet-18, ResNet-101, VGG-16, and VGG-19), and Support Vector Machine classifier with features extracted from these networks. Furthermore, a comprehensive performance analysis is conducted using various image preprocessing techniques such as color channels, color model transformation, data augmentation, histogram equalization, and background elimination with segmentation, individually and in combination. The experiments were conducted on the Li and D0 datasets containing 10 and 40 insect pest species, respectively.

Findings

As a result of the experiments, the highest performances were obtained on both datasets, with accuracy rates of 96.3 and 99.63%, respectively, using data augmentation and transfer learning with the ResNet-101 network. The experimental results indicate that the proposed models can be effectively used in insect pest control. The proposed models achieve high performance comparable to or surpassing results reported in the literature.

Practical implications

This paper demonstrates that deep learning-based methods can achieve high accuracy in identifying insect pests and suggests several practical implications for agricultural practices and pest management: improved insect pest classification and pest control strategies, reduced agricultural losses, and data-driven decision-making.

Social Implications

The research on deep learning-based methods for detecting and controlling insect pests has the potential to impact society in several significant ways: 1) Agricultural Sustainability and Environmental Impact: The proposed models' high accuracy rates in early pest detection can lead to more targeted pest control strategies. This precision reduces the need for broad-spectrum pesticides, contributing to a decrease in chemical usage in agriculture. As a result, the environmental impact of farming can be minimized, promoting more sustainable practices and reducing harm to non-target species and ecosystems, 2) Economic Benefits and Food Security: Effective detection and control of insect pests can lead to increased crop yields and reduced agricultural losses.

Originality

Various deep learning models and image preprocessing techniques were utilized to conduct a comprehensive performance analysis. With the new methods employed in experiments on two different datasets, results comparable to or superior to those in the literature were achieved.

[†] Corresponding author: skb@eskisehir.edu.tr, +90-222-213-8110

1. Giriş (Introduction)

Tarım, insanların sağlıklı bir yaşam sürmeleri için temel gıda ürünlerinin üretimi, kalitelerinin artırılması, bu ürünlerin uygun şartlarda depolanması ve işlenip değerlendirilmesi ile ilgilenen bir sektördür. Dünya nüfusu artmaya devam ettikçe mahsul verimliliğini, ekonomik istikrarı ve çevrenin korunmasını sağlamak için sürdürülebilir ve dayanıklı tarım uygulamalarına yönelik talep artmaktadır. Tarımda verimli gıda üretimi sağlamak önemlidir ve tarımla ilgili çoğu çalışmada, ürünü korumaya yönelik olarak iklim değişikliğinin mahsuller üzerindeki yan etkisi, toprak sağlığının bozulması, su kıtlığı, haşere ve hastalık yönetimi gibi çözüme ihtiyaç duyan sorunlara, yenilikçi teknolojiler ile cevap veren konular ele alınmaktadır. Bitkinin kalitesinde, gelişiminde ve fiziksel yapısında olumsuz etkiye neden olmalarından dolayı başlıca tarım sorunlarından biri zararlı böceklerdir. Karmaşık yapılara ve farklı türler arasında görünüş benzerliğine sahip olmaları, bu zararlı böceklerin doğal ortamından ayırt edilebilmesini zorlaştırmaktadır. Mahsul hastalıklarına ve önemli ürün kayıplarına neden olan zararlı böceklerin yayılmasının önlenmesi için mahsullerdeki bu zararlıların erken dönemde tespiti ve sınıflandırılması oldukça önemlidir. Bu sorunun çözümüne yönelik olarak son zamanlarda görüntü işleme ve derin öğrenme tekniklerine dayalı çeşitli yöntemler geliştirilmiştir (Distante vd., 2020).

(Xia vd., 2018) çalışmasında 24 sınıflı mahsul zararlılarını içeren Xie1 veri setindeki (Xie vd., 2015) görüntülerde böceklerin hızlı ve doğru bir şekilde tespit edilmesi için VGG-19 ağı kullanılmıştır. Ayrıca yazarlar, ön işleme adımı olarak, veri setinin küçük olması sebebiyle tüm görüntüleri 90°, 180°, 270° açılarda döndürerek veri artırımı, aynı zamanda verilerin geçerliliğini sağlamak amacıyla görüntülerdeki piksel değerlerini rastgele değiştiren, bazı piksel noktalarını beyazlatan bazı piksel noktalarını karartan tuz ve biber gürültüsünü görüntülere eklemişler ve %89.22 mAP (mean Average Precision) değerine ulaşmışlardır. (Xie vd., 2018) çalışmasında yazarlar haşere görüntülerinin sınıflandırılmasında çok seviyeli öğrenme özniteliklerini içeren temsilleri oluşturmak için üç adım izlemişlerdir. İlk adım olan denetimsiz sözlük öğrenme aşamasında, görüntü parçalarından özniteliklerin çıkarılması hedeflenmiştir. İkinci adım, öznitelik kodlama aşamasında görüntü parçalarının öznitelikleri, önceden oluşturulan sözlüğe göre kodlanır. Üçüncü ve son adımda çok seviyeli bir örnekleme süreci uygulanır. Bu süreçte, parça düzeyindeki özniteliklerin yanlış hizalama sorununu çözmek için filtreler birden çok ölçekte uygulanır ve bu çeşitli havuzlama seviyeleriyle birleştirilerek özniteliklerin daha doğru bir şekilde çıkarılmasını sağlamaktadır. Bu üç adımın birleşimi ile haşere görüntülerinin çok seviyeli öğrenme özniteliklerine dönüştürülmesini sağlamışlardır. Deneyleri dört veri seti üzerinde gerçekleştirmişlerdir. Kendi oluşturdukları D0 veri setinde %89.30 doğruluk değeri olmak üzere en yüksek sonucu D1 (Xiao vd., 2012) veri setinde %98.6 sınıflandırma doğruluğu ile elde etmişlerdir.

(Thenmozhi ve Reddy, 2019) çalışmasında yazarlar, AlexNet, ResNet, GoogLeNet ve VGGNet gibi önceden eğitilmiş derin sinir ağlarını üç farklı genel veri seti NBAIR, Xie1 ve D0 üzerinde transfer öğrenme yöntemini kullanarak deneylerini gerçekleştirmişlerdir. Ağın aşırı uyumunu önlemek için yansıtma, ölçeklendirme, döndürme ve görüntülerin konumunu değiştirme gibi veri artırma teknikleri de uygulamışlardır. Deneyler sonucunda ulaştıkları doğruluk değerleri NBAIR'de %96.75, Xie1'de %97.47 ve D0'da %95.97'dir. (Wu vd., 2019) çalışmalarında, 102 sınıfa ait 75.000'den fazla görüntü içeren IP102 adlı büyük ölçekli bir veri seti tanıtılmıştır. Yazarlar, destek vektör makinesi (SVM) ve K-En yakın komşu sınıflandırıcısını kullanarak %49.50 doğruluk elde etmişlerdir. (Nanni vd., 2020) çalışmasında, bitki zararlılarını sınıflandırmak için görüntünün en önemli piksellerini vurgulamak amacıyla belirginlik yöntemleri ve evrimsel sinir ağlarının (CNN, ing. Convolutional Neural Network) kombinasyonuna dayanan otomatik bir sınıflandırıcı önerilmiştir. Önerilen yöntemin performans değerlendirmesini, 10 sınıflı bir veri seti (Deng vd., 2018) ve 102 sınıflı IP102 veri seti (Wu vd., 2019) üzerinde gerçekleştirmişlerdir. Önerilen yaklaşımları ile, küçük ölçekli veri setinde %92.43 ve IP102 veri setinde ise %61.93 başarı oranına ulaşmışlardır. (Li vd., 2020) çalışmasında ise yazarlar, manuel olarak toplanan ve on farklı mahsul zararlısı türünü içeren Li olarak adlandırdıkları yeni bir veri seti oluşturmuşlardır. Bu veri setinde zararlı sınıflandırması için önceden eğitilmiş VGG-16, VGG-19, ResNet50, ResNet-152 ve GoogLeNet ağları kullanarak yaptıkları deneyler sonucunda en yüksek performans olan %96.67 doğruluk değerine ince ayar yaptıkları GoogLeNet modeliyle ulaşmışlardır. (Yang vd., 2021b) çalışmasında, yazarlar sera ortamındaki beyaz sineklerin tanınması ve sayımı için, seradan toplanan kendi oluşturdukları veri seti üzerinde görüntü işleme teknikleri kullanmıştır. Çalışmalarında, zararlıları tespit etmek için HSI renk uzayının I bileşeninde Prewitt operatörü ve Lab renk uzayının b bileşeninde Canny operatörü kullanan bir yöntem önermişlerdir. Bu yöntem ile, görüntüleri iki farklı renk uzayında işleyerek ve çoğunluk oylama uyguladıkları topluluk öğrenme ile %95.73 tanıma doğruluğu elde etmişlerdir. (Chen vd., 2023) çalışmasında yazarlar, biber hastalıklarının ve zararlılarının tanınmasında HSV renk uzayını kullanan CNN'lere dayalı bir tanıma yöntemi önermişlerdir. Önerdikleri algoritma ile, RGB renk uzayı ile %66.15 hassasiyet ve %51.48 kesinlik, HSV renk uzayı ile %72.44 hassasiyet ve %63.26 kesinlik değeri elde etmişlerdir. (Toscano vd., 2024) çalışmasında, koza kurdu popülasyonlarının sınıflandırılma performansının iyileştirilmesi için transfer öğrenme tekniklerinin kullanımı araştırılmıştır. Makine öğrenimi algoritmalarının performansını artırmak amacıyla örnek tabanlı, öznitelik tabanlı ve parametre tabanlı transfer öğrenme teknikleri üzerinde durulmuştur. Az örnekli ve az öznitelikli veri setleri kullanılarak, koza kurdu saldırı seviyesini tahmin etmek için iklim

değişkenlerini de dahil etmişlerdir. Sonuçlar, az örneklı durumda %90.79, az öznelikli durumda ise %96.28 doğrulukla, transfer öğrenme tekniklerinin sınıflandırma performansını iyileştirdiğini göstermiştir.

Sınıflandırma aşamalarının performansının artırılması için görüntülerin kalitesinin artırılması ve görsel özelliklerinin iyileştirilmesine ihtiyaç duyulmaktadır. Bu çalışmada, bitki zararlılarının etkili bir şekilde tespit edilip kontrol altına alınmalarını sağlamak amacıyla, farklı görüntü ön işleme ve derin öğrenme tekniklerine dayalı sınıflandırma modelleri önerilmiştir. Önerilen modeller, GoogLeNet (Szegedy vd., 2015), ResNet-18 (He vd., 2016), ResNet-101 (He vd., 2016), VGG-16 (Simonyan ve Zisserman, 2014) ve VGG-19 (Simonyan ve Zisserman, 2014) gibi önceden eğitilmiş beş farklı derin sinir ağı ile transfer öğrenimi ve bu ağlardan çıkarılan öznelikler ile Destek Vektör Makinesi (SVM) sınıflandırıcısını kullanmaktadır. Deneyler, sırasıyla 10 ve 40 bitki zararlısı türü içeren Li ve D0 veri setleri üzerinde gerçekleştirilmiştir. Bitki zararlılarının tespitinde, renkleri ve kontrastı dengelemek ve görüntüyü daha anlamlı bir şekilde analiz etmek için farklı ön işleme tekniklerinin etkisi üzerine çalışılmıştır. Renk kanalı, veri artırımı, histogram eşitleme, segmentasyon ile arka plan eliminasyonu gibi farklı görüntü ön işleme teknikleri ayrı ayrı ve birlikte kullanılarak kapsamlı bir performans analizi yapılmıştır.

Makalenin genel akışı şu şekilde organize edilmiştir: Bölüm 2'de kullanılan veri setlerinin içeriği hakkında bilgi verilmiş, önerilen sınıflandırma modelleri ve kullanılan farklı görüntü ön işleme teknikleri ayrıntılı bir şekilde açıklanmıştır. Bölüm 3'te deneysel çalışmalar ve bu çalışmaların sonuçları sunulmuştur. Bölüm 4'te ise, son olarak çalışma ile ilgili genel değerlendirmeler ve gelecek çalışmalar için öneriler yer almaktadır.

2. Materyal ve Yöntem (Material and Method)

2.1. Veri Seti (Dataset)

Bu çalışmada, performans ölçümü için iki farklı veri seti kullanılmıştır. Bunlardan ilki, (Li vd., 2020) çalışmasında oluşturulan ve Grylotalpa, Leafhopper, Locust, Oriental Fruit Fly, Pieris Rapae Linnaeus, Snail, Spodoptera Litura, Stinkbug, Cydia Pomonella, Weevil olmak üzere 10 farklı sınıfa ait toplamda 5689 görüntü içeren bir mahsul zararlısı veri setidir. Şekil 1'de, Li veri setindeki her bir sınıfa ait örnek bir görüntü verilmiştir. Li veri seti, Google, Baidu, Yahoo ve Bing gibi popüler arama motorlarından elde edilen görsellerle birlikte, Li vd. tarafından Apple 7 Plus cep telefonu kullanılarak dış mekân çekimleri yapılarak oluşturulmuştur. Bu haşereler genellikle küçük boyutlara sahip olduklarından doğal ortamlarında çıplak gözle bile hızlı bir şekilde tespit etmek ve özellikle tarlaya bulaştıklarında kurtulmak zordur. Bu sebeple mahsul veriminde büyük kayıplara neden olabilirler. İkinci olarak ise, (Xie vd., 2018) çalışmasında oluşturulan mısır, soya fasulyesi, buğday ve kanola dahil olmak üzere birçok yaygın tarla ürününde bulunan türlerin çoğunu kapsayan 40 farklı böcek sınıfını içeren ve 4508 RGB görüntüden oluşan açık erişimli D0 veri seti kullanılmıştır. Şekil 2'de ise, D0 veri setindeki sınıflara ait örnek görüntüler listelenmiştir.



Şekil 1. Li Veri Setindeki 10 Farklı Sınıfa Ait Örnek Görüntüler (Sample Images of 10 Different Classes in the Li Dataset)



Şekil 2. D0 Veri Setindeki 40 Farklı Sınıfa Ait Örnek Görüntüler (Sample Images of 40 Different Classes in the D0 Dataset)


2.2. Ön İşleme Teknikleri (Preprocessing Techniques)

Veriler, genellikle gürültü, bozulma, eksik ve tutarsız bilgiler gibi çeşitli sorunlar içerebilir. Bu nedenle, veri analizi ve diğer veri odaklı uygulamalarda güvenilir sonuçlar elde etmek için öncelikle ön işleme adımlarının gerçekleştirilmesi gerekmektedir. Veri ön işleme, verilerdeki gürültüyü azaltmak, eksik veya tutarsız verileri düzeltmek, gereksiz özellikleri temizlemek ve genel olarak veri kümesinin homojenliğini sağlamak için kullanılan farklı teknikleri içermektedir. Sınıflandırma ve tespit uygulamalarında kullanılan veri setlerini hazırlamak için farklı ön işleme yöntemleri mevcuttur. Bu adımlar, veri olarak görüntüler ele alındığında döndürme, temizleme, veri artırımı ve renk modeli dönüşümü gibi sınıflandırma algoritmalarının daha güvenilir ve etkili olmasını sağlamak için kritik öneme sahip olan uygulamalardır (Maharana vd., 2023).

Görüntü ön işleme sürecinde, farklı renk kanalları ve renk modelleri önemli bir rol oynar. Görüntülerin renklerini temsil etmek için kullanılan Kırmızı (R), Yeşil (G), ve Mavi (B) olmak üzere üç temel renk bileşeni bulunmaktadır. Bu renk bileşenleri, bir görüntünün renk paletini oluşturan temel yapı taşlarıdır. Yüksek bir R değeri, görüntüdeki kırmızı tonların belirginliğini artırırken, yüksek bir G değeri yeşil tonların ve yüksek bir B değeri de mavi tonların belirginliğini artırır. Bu bileşenler, farklı oranlarda birleşerek renklerin zenginliğini oluşturur ve görsel deneyimi çeşitlendirir. Renk kanallarının ayrı ayrı kullanımı ile karmaşık görüntü işleme problemleri basit parçalara ayrılır ve daha sonraki algoritma adımları için işlem kolaylığı sağlanır.

Bu çalışmada farklı modellerin bitki zararlısı sınıflandırma için önerilmesinin yanı sıra, görüntü ön işleme sürecinde, belirli renk kanalı, histogram eşitleme, segmentasyon ile arka plan eliminasyonu ve veri artırımının sınıflandırma performansına etkisi araştırılmaktadır. Çalışmada kullanılan ön işleme teknikleri, belirli renk kanalı üzerinden görüntülere renk ayarı, kontrast artırma ve renk dengeleme yapılması gibi işlemleri içermektedir. Histogram eşitleme, zayıf kontrastlı görüntülerin kontrastını artırır ve görüntünün piksel değerlerinin dağılımını değiştirerek görüntüyü daha net ve detaylı hale getirir. Görüntülerdeki zararlıların genellikle yeşil bitkiler üzerinde olduğu değerlendirilerek, modele girdi olarak görüntünün G kanalı verilmiştir. Bu yeşil renk kanalının çıkarılmasıyla görüntüdeki zararlılar daha belirgin hale gelmiştir. Görüntülerde arka plan karmaşıklığından kaynaklı böceği tespit edememe durumunu ortadan kaldırmaya yönelik derin öğrenme tabanlı bir segmentasyon yöntemi olan ve piksel düzeyinde arka plana ait olasılık haritasını tahmin eden U-Net tabanlı mimari (Qin vd., 2020) kullanılarak bitki zararlıları segmente edilip, ardından arka plan elimine edilmiştir. Veri setindeki görüntülerin artırımı, bitki zararlılarının tanınması, tespiti ve kullanılan modelin öğrenimi açısından kolaylık sağlamaktadır (Nanni vd., 2020). Veri artırımı işlemi; iki veri setinde de test verileri sabit tutularak, eğitim verilerine çeşitli döndürme ve yansıtma yöntemleri uygulanarak gerçekleştirilmiştir. Görüntüler, 90° döndürme ve X yansıma, 120° döndürme ve Y yansıma gibi yöntemlerle artırılmıştır. Veri artırımı sonrasında her sınıf için üç

kat artırımı yapılmıştır. Görüntülerde veri artırımı, görüntü sınıflandırma problemlerinde farklı tekniklerle (döndürme, ölçeklendirme, yansıma vb.) mevcut veri setini çoğaltarak modelin genelleme yeteneğini iyileştirir ve aşırı öğrenmeyi azaltır. Bu yöntem, özellikle küçük veri setlerinde faydalıdır, çünkü modelin daha çeşitli ve zengin bir veri ile eğitilmesini sağlar, böylece doğruluk oranlarını artırır ve modelin daha sağlam hale gelmesine yardımcı olur. Ayrıca, veri artırımı sınıflar arasındaki dengesizliği gidererek her sınıfı eşit derecede öğrenmeyi teşvik eder ve modelin gerçek dünya senaryolarında daha iyi performans göstermesine katkıda bulunur (Shorten ve Khoshgoftaar, 2019). Tüm ön işleme sürecine ait örnek görüntüler Şekil 3'te sunulmaktadır.



Şekil 3. Ön İşleme Teknikleri Uygulanmış Örnek Görüntüler. (a) Orijinal Görüntü, (b) 90° Döndürme + X Yansıma, (c) 120° Döndürme + Y Yansıma, (d) X Yansıma + Y Yansıma (e) G Kanalı Çıkarımı, (f) Histogram Eşitleme, (g) Segmentasyon ile Arka Plan Eliminasyonu

2.3. Önerilen Sınıflandırma Modelleri (Proposed Classification Models)

Bu çalışmada önerilen ilk yöntem olan çeşitli önceden eğitilmiş derin sinir ağları ile transfer öğrenimi, az sayıda eğitim görüntüsüyle bile yüksek sınıflandırma performansı elde edilebilmesine olanak sağlamaktadır. Transfer öğrenimde, önceden eğitilmiş bir model, farklı veri setlerinde kullanılabilir ve bu modelin daha önceden öğrendiği özellikler, diğer görevlerde de yararlı olabilir. Bu nedenle, önceden eğitilmiş modeldeki belirli katmanlar değiştirilerek, yeni görev için yeniden eğitilir ve yeni bir model oluşturulur. Bu yöntem sayesinde model eğitimi esnasında zamandan tasarruf sağlanır. Transfer öğrenimi ile önceden eğitilmiş bir sinir ağını kullanmak, genellikle bir sinir ağını sıfırdan eğitmekten çok daha hızlı ve kolaydır. Bu ağlar bir milyondan fazla görüntü üzerinde eğitilmiştir ve görüntüleri klavye, kahve kupası, kalem ve birçok hayvan gibi 1000 nesne kategorisine göre sınıflandırabilmektedir. ILSVRC yarışmasında, ImageNet veri kümesi kullanılarak en iyi görüntü sınıflandırma ve nesne algılama modellerini belirlenmiş aynı zamanda sinir ağlarının performansını artırmak ve genelleme yeteneklerini geliştirmek için kullanılmıştır.


Çalışmada kullanılan önceden eğitilmiş ağlar hakkında detaylı bilgiler Tablo 1'de verilmiştir. Önceden eğitilmiş ağlar yardımıyla transfer öğrenme, segmentasyon, nesne tanıma ve sınıflandırma gibi çok çeşitli uygulama alanı için model geliştirilebilir.

Tablo 1. Önceden Eğitilmiş Derin Sinir Ağları

Önceden Eğitilmiş Ağ	Girdi Görüntüsü Boyutu	Derinlik	Katman Sayısı	Aktivasyon (Öznitelik Sayısı)
ResNet-18	224x224	18	71	512
ResNet-101	224x224	101	347	2048
GoogLeNet	224x224	22	144	1024
VGG-16	224x224	16	41	512
VGG-19	224x224	19	47	512

İkinci yöntemde ise, önceden eğitilmiş derin sinir ağlarının çeşitli katmanlarından elde edilen derin ve sığ özellikler ile SVM sınıflandırıcısı kullanılmaktadır. Önceden eğitilmiş ağların ara katmanlarından çıkarılan sığ özellikler, verinin temel özelliklerini temsil eder. Bu özellikler genellikle düşük seviyeli, basit ve yerel özellikleri içerir. Önceden eğitilmiş ağların son katmanından çıkarılan derin özellikler ise, daha karmaşık ve soyut düzeyde veri özelliklerini temsil eder. Bu özellikler genellikle daha yüksek seviyeli anlam taşırlar. Derin katmanlar, daha önceki katmanların alt düzey özelliklerini kullanarak daha yüksek seviyeli özellikleri oluşturur.

Şekil 4'te önerilen derin öğrenme tabanlı sınıflandırma modellerinin genel çerçevesi verilmiştir.



Şekil 4. Önerilen Modellerin Genel Çerçevesi

3. Deneysel Sonuçlar (Experimental Results)

Önerilen modellerin performanslarının değerlendirilebilmesi için kapsamlı deneysel çalışmalar gerçekleştirilmiştir. Tüm deneylerde doğruluk (D), kesinlik (K, ing. precision), hassasiyet (H, ing. recall) ve F1 skoru (F1) gibi standart değerlendirme ölçütleri kullanılmıştır. Bu ölçütler, her modelin sınıflandırma yeteneğini farklı açılardan değerlendirerek güvenilir bir karşılaştırma yapılmasına olanak sağlamaktadır. Deneyler, yüksek performanslı bir Intel(R) Core (TM) i7-7700HQ, 2.80GHz işlemci ve 16 GB RAM'e sahip bilgisayar ortamında gerçekleştirilmiştir. Deneylerde hiper parametrelerin doğru ayarlanması, modelin en iyi sonuçları elde etmesi açısından kritik öneme sahiptir. Hiper parametre ayarları, modelin öğrenme sürecini ve performansını etkileyen önemli faktörlerdir. Çalışmada maksimum adım sayısı 5 ile 30 arasında ayarlanmıştır. Öğrenme oranı ve mini-batch boyutu sırasıyla 0.001 ve 64 olarak ayarlandığında modellerin en iyi sonuçları verdiği görülmüştür. Bu nedenle, kullanılan yaklaşımların etkisini değerlendirmek için yapılan diğer deneylerde parametreler bu değerlerde sabit tutulmuştur.

Deneysel çalışmalar için tarlalarda yaygın bulunan ve mahsul verimini etkileyen bitki zararlılarının görüntülerinden oluşan orijinal 10 sınıflı Li ve 40 sınıflı D0 veri setlerindeki görüntüler, %70 eğitim ve %30 test olmak üzere iki farklı alt gruba ayrılmıştır. Eğitim alt grubu, verilerin öğrenme süreci için ve test alt grubu ise sadece performans ölçümü için kullanılmıştır. Önerilen modellerin performansları, Li veri seti için Tablo 2'de ve D0 veri seti için Tablo 3'te sunulmuştur. Tablolarda, her bir modelin Li ve D0 veri setlerindeki doğruluk, kesinlik, hassasiyet ve F1 skorları yer almaktadır. En yüksek performansa sahip model kalın olarak işaretlenmiştir. Bu tablolar kullanılarak, orijinal görüntülerde en yüksek F1 skora sahip yöntem belirlenmiş, daha sonra farklı görüntü ön işleme yöntemlerinin performanslarının karşılaştırılması için kullanılmıştır.

Tablo 2 incelendiğinde, önerilen modellerin sınıflandırma sonuçlarına göre her bir performans ölçütü için en yüksek performans ResNet-101 ağı ile transfer öğrenme yöntemi kullanılarak elde edilmiştir. Benzer şekilde, bu veri seti üzerinde kullanılan tüm önceden eğitilmiş ağlar için kullanılan yöntemler karşılaştırıldığında ise transfer öğrenmenin diğer iki yönteme kıyasla daha iyi performans gösterdiği gözlemlenmiştir. Deneylerin ortalama test süreleri transfer öğrenme, derin öznelikler ile SVM ve sığ öznelikler ile SVM kullanıldığında sırasıyla 112, 15 ve 3 saniyedir. Tablo 3 incelendiğinde, D0 veri seti üzerinde yapılan deneylerde de Tablo 2'dekine benzer bir sonuç elde edilmiştir. Bu sonuç, ResNet-101 ağının D0 veri setindeki öznelikleri de diğer ağlardan daha etkili bir şekilde çıkarabildiğini ve genelleme yeteneğinin diğer mimarilere göre daha güçlü olduğunu göstermiştir. Deneylerin ortalama test süreleri transfer öğrenme, derin öznelikler ile SVM ve sığ öznelikler ile SVM kullanıldığında sırasıyla 95, 27 ve 5 saniyedir.

Sonuç olarak, Tablo 2 ve Tablo 3, her iki veri setinde de ResNet-101 ağının transfer öğrenme ve SVM ile sınıflandırma sürecinde diğer ağlara kıyasla belirgin olarak daha üstün bir performans sağladığını ortaya koymaktadır. Test süresi karşılaştırması yapıldığında transfer öğrenme yöntemi daha yavaş olmasına rağmen doğruluk açısından daha iyi performans göstermiştir. Bu nedenle, ikinci aşama olan farklı ön işleme yöntemleriyle gerçekleştirilen tüm deneylerde, önceden eğitilmiş ağ olarak ResNet-101 ağı ile transfer öğrenme yönteminin kullanılmasına karar verilmiştir. Bu seçim, modelin genel başarı oranını artırmak ve güçlü bir temel öğrenme yeteneği sağlamak amacı ile yapılmıştır. Ayrıca, aynı yöntemin sabit kalması, daha sonraki deneyler sırasında değişkenlikleri minimize ederek daha güvenilir ve başarılı sonuçlar elde etme olasılığını artırmaktadır.

Derin öğrenme modelleri genellikle kullanılan ağın ne öğrendiğini ve ağa verilen girdinin hangi kısmının çıktı sınıfından sorumlu olduğunu belirtmez. Bunu öğrenebilmek ve kullanılan ağların tahminlerine görsel açıklamalar getirmek için kullanılabilir tekniklerden biri sınıf aktivasyon haritalamadır. Sınıf aktivasyon haritalama, eğitim setindeki ön yargıyı belirlemek ve model doğruluğunu artırmak amacıyla da kullanılmaktadır. Eğer ağın tahminleri yanlış özelliklere dayandığı keşfedilirse, veri seti üzerinde değişiklik yapılarak ağ daha sağlam hale getirilebilir. Şekil 5, orijinal Li ve D0 veri setlerinde, çeşitli sınıflara ait ResNet-101 ağı ile elde edilen sınıf aktivasyon haritalarını göstermektedir. Burada kırmızı bölgeler tahmin edilen sınıfa en çok katkıda bulunan bölgelerdir.

Tablo 2. Önerilen Modellerin Orijinal Li Veri Setindeki Performansları (%) (D/K/H/F1)

Önceden Eğitilmiş Ağ	Transfer Öğrenme	SVM ile Derin Öznelikler	SVM ile Sığ Öznelikler
GoogLeNet	94.89/94.82/94.50/94.66	92.78/92.52/92.51/92.51	80.34/79.18/78.52/78.85
ResNet-101	95.91/95.69/95.60/95.65	94.89/94.56/94.66/94.61	94.66/94.42/94.33/94.37
ResNet-18	94.77/94.53/94.36/94.44	91.93/91.79/91.33/91.56	91.36/91.45/90.78/91.11
VGG-16	93.86/93.62/93.46/93.62	91.88/91.52/91.15/91.34	90.68/89.92/90.25/90.08
VGG-19	94.49/94.20/93.99/94.09	92.67/92.28/92.12/92.20	89.43/89.05/88.89/88.97

Tablo 3. Önerilen Modellerin Orijinal D0 Veri Setindeki Performansları (%) (D/K/H/F1)

Önceden Eğitilmiş Ağ	Transfer Öğrenme	SVM ile Derin Öznelikler	SVM ile Sığ Öznelikler
GoogLeNet	99.41/99.37/99.36/99.37	98.89/98.95/98.84/98.89	98.89/98.95/98.84/98.89
ResNet-101	99.56/99.57/99.59/99.58	99.41/99.45/99.43/99.43	99.41/99.49/99.33/99.41
ResNet-18	99.33/99.46/99.30/99.38	98.74/98.61/98.57/98.59	98.74/98.61/98.57/98.59
VGG-16	99.26/99.06/99.27/99.16	97.78/98.02/97.62/97.82	98.30/98.32/98.28/98.30
VGG-19	98.96/99.01/98.95/98.98	98.15/98.28/98.12/98.20	98.74/98.70/98.60/98.65



Şekil 5. Kullanılan Veri Setlerine Ait Örnek Görüntülerdeki ResNet-101 Aktivasyon Haritası. (a) Li, (b) D0

Tablo 4. Önerilen Modellerin Farklı Ön İşleme Yöntemleri ile Elde Edilen Performansları (%) (D/K/H/F1)

Ön İşleme Yöntemi	Li Veri Seti	D0 Veri Seti
RGB (Orijinal)	95.91/95.69/95.60/95.65	99.56/99.57/99.59/99.58
G Kanalı Çıkarımı	92.73/92.33/92.33/92.33	98.96/98.80/98.83/98.82
Veri Artırımı	96.36/96.19/95.91/96.06	99.63/99.68/99.67/99.68
Histogram Eşitleme	94.83/94.52/94.30/94.41	99.19/99.26/99.28/99.27
Histogram Eşitleme+Veri Artırımı	95.17/95.01/94.65/94.83	99.26/99.34/99.35/99.34
Segmentasyon ile Arka Plan Eliminasyonu	93.30/93.10/92.86/92.98	98.52/98.61/98.30/98.46
Veri Artırımı+Segmentasyon ile Arka Plan Eliminasyonu	93.58/93.52/92.74/93.13	98.74/98.74/98.52/98.63

Tablo 4'te, seçilen ağın performansını daha da artırmak için kullanılan farklı veri ön işleme yöntemleri ve sonuçları verilmiştir. Bu çalışma, ResNet-101 ağı ile birleştirilen doğru ön işleme yöntemlerinin, haşere sınıflandırma modelinin performansını artırma potansiyelini göstermektedir. Bu aşamada, veri seti öncelikle farklı ön işleme adımlarından geçirilmiş olup bunlar; görüntüden G kanalının çıkarılması, veri artırımı, histogram eşitleme, segmentasyon ile arka plan elimine etme ve kombinasyonları şeklindedir. Ön işleme aşamasında elde edilen görüntüler ResNet-101 ağı ile transfer öğrenme kullanılarak elde edilen modele girdi olarak verilmiştir. Sonrasında model eğitim görüntüleri ile eğitilmiştir. Veri ön işleme adımları, modelin daha etkili bir şekilde öğrenmesine ve genel performansını artırmaya yönelik çeşitli işlemleri içermektedir. Histogram eşitleme kontrastı artırırken, veri artırımı, modelin çeşitli açılardan öğrenme yeteneğini artırarak aşırı uyuma karşı daha dirençli bir yapı oluşturmaktadır.

Sonuçlar incelendiğinde, RGB görüntüler üzerindeki orijinal veri seti kullanıldığında sonuç ile kıyaslandığında, G kanalının yeterli performans gösteremediği görülmektedir. Bu durum, yeşil renk kanal çıkarımının tek başına görüntü verilerini yeterince temsil etmekte yetersiz kaldığını işaret etmektedir. Buradan modelin öznelilik çıkarımı ve sınıflandırma yeteneğini sınırladığı sonucuna varılmıştır. Histogram eşitleme orijinal veri setindeki sonuç ile yakın performans göstermiştir. Bu yöntemin renk bilgisi ve öznelilik çıkarımı süreçlerinde etkili olduğunu ortaya koymaktadır. Histogram eşitleme, görüntünün kontrastını artırarak daha belirgin özelliklerin ortaya çıkmasına olanak tanır ve daha doğru ve ayrıntılı özneliliklerin elde edilmesine katkı sağlar. Arka plan eliminasyonunun orijinal veri setindeki sonuç ile kıyaslandığında daha başarısız olduğu gözlemlenmiştir. Burada kullanılan iki aşamalı yaklaşımda, öncelikle U-net kullanılarak bitki zararlıları arka plandan ayrılmış, ilk aşama olan segmentasyon aşamasından elde edilen zararlı görüntüleri kullanılarak sınıflandırma aşamasına geçilmiştir. Bu yaklaşımın performansı, zararlı segmentasyonunun doğruluğuna ve modelin bu segmente edilmiş verilerden öğrenme yeteneğine bağlıdır. Arka plan eliminasyonunda kullanılan segmentasyon yönteminin görüntüyü maskeleyerek zararlı ve arka planın benzer olması sebebiyle yanıltıcı maskelemeler yaptığı görülmüştür. Ayrıca bazı zararlı türlerinin sınıflandırılmasında arka plan bilgisinin önemli olabileceği değerlendirilmiştir. Örneğin belirli zararlı türlerinin sadece belirli bitki türlerinde bulunması ve bu bitkilerin varlığı zararlıların sınıflandırılmasında yardımcı olabilir. Arka planı tamamen kaldırmak, bu tür bir bilgi kaybına yol açarak sınıflandırma performansını olumsuz etkileyebilmektedir. Veri artırımı ile veri setleri çeşitli yansıtma, döndürme yöntemleri ile üç kat artırılmıştır ve modelin performansı üzerinde olumlu olarak belirgin bir etkisi olduğu gözlemlenmiştir. RGB görüntü üzerinde uygulanan veri artırımının her iki veri setinde de en yüksek başarı sonuçlarını elde etmede etkili olduğu tespit edilmiştir. Sonuç olarak, bu çalışma, ResNet-101 ağıyla birleştirilen belirli ön işleme yöntemlerinin, özellikle RGB görüntü üzerinde uygulanan veri artırımının, bitki zararlısı sınıflandırma modelinin performansını artırmada önemli bir rol oynayabileceğini göstermiştir. Bu sonuçlar, bitki

zararlılarının etkili bir şekilde sınıflandırılması için uygun ön işleme stratejilerinin seçilmesinin önemini vurgulamıştır.

4. Sonuç ve Tartışma (Result and Discussion)

Bitkilerin korunması için, bitki zararlılarının doğru bir şekilde tanınması oldukça önemlidir. Bunların erken tespiti, tarım ekonomisindeki kayıpların azaltılmasına yardımcı olmaktadır. Son zamanlarda derin öğrenme tabanlı yöntemler, hızlı ve doğru bir bitki zararlısı sınıflandırıcısı geliştirmenin en etkili yollarından biri haline gelmiştir. Bu yaklaşım, büyük veri setlerini işleyebilme yeteneği ve karmaşık öznitelikleri otomatik olarak çıkarma kabiliyeti sayesinde, çeşitli bitki zararlılarını doğru bir şekilde tanımlamak için güçlü bir araç sunmaktadır.

Bu çalışmada bitki zararlılarının tespiti ve sınıflandırılması için, ilk yöntem olarak önceden eğitilmiş ağlar ile transfer öğreniminden yararlanılmıştır. İkinci yöntem olarak bu ağlardan çıkarılan hem derin hem de sığ öznitelikler kullanılarak SVM sınıflandırıcısı ile sınıflandırma işlemi gerçekleştirilmiştir. Ayrıca farklı ön işleme yöntemlerinin, önceden eğitilmiş derin sinir ağlarının özniteliklerini kullanarak transfer öğrenme ile sınıflandırma performansını nasıl etkilediği araştırılmıştır. Model için en uygun özniteliklerin seçilmesi ve veri setinden kaynaklanan zorlukların giderilmesi ile her iki veri setinin de kalitesi artırılmıştır. Çalışmada histogram eşitleme, veri artırımı ve görüntünün G renk kanalı çıkarım ve U-Net mimarisi kullanılarak segmentasyon ile arka plani elimine etme gibi ön işleme tekniklerinin bitki zararlısı tespit ve sınıflandırma performansına olan etkisi ölçülmüştür.

Tablo 5. Önerilen Çalışmanın Literatürde Yer Alan Benzer Çalışmalar ile Karşılaştırması

Referans	Veri seti (#Sınıf, #Görüntü)	Ön İşleme Yöntemi	Model	Performans (%)	İşlem süresi (sn)
(Xia vd., 2018)	Xie1 (24,1440)	Veri artırımı	VGG-19	mAP: 89.22	Eğitim: 40320
(Thenmozhi ve Reddy, 2019)	D0 (40, 4508) Xie1 (24,1440) NBAIR (40)	Veri artırımı	CNN	D: 95.97 D: 97.47 D: 96.75	- - -
(Li vd., 2020)	Li (10, 5869)	Veri artırımı Arka plan temizleme	GoogLeNet	D: 96.67	-
(Nanni vd., 2020)	IP102 (102, 75222) Deng (10,563)	Veri artırımı	CNN Belirginlik yöntemi	D: 61.93 D: 92.43 D: 96.78	- - -
(Yang vd., 2021a)	Li (10, 5869) IP102 (102, 75222) Özel Veri Seti (58, 7344)	Veri artırımı Derin öznitelikler Kendi oluşturdukları öznitelikler Veri artırımı	STN (Spatial Transformer Networks) ResNet-50	D: 73.29 D: 96.50	Test: 165 -
(Yang vd., 2021b)	Özel Veri Seti	Renk uzayı analizi	Karar ağaçları Topluluk öğrenme	D: 95.73 F1:93.56	-
(Chen vd., 2023)	PlantVillage (2, 2475)	Renk modeli dönüşümü	CNN	K: 63.26, H: 72.44	-
(Wang vd., 2023)	IP102 (102, 75222) D0 (40, 4508) Insect (9, 2251)	Veri artırımı	ConvNeXt ve SwinTransformer	D: 71.60, H: 71.20, F1: 71.40 D: 98.50, H: 98.20, F1: 98.40 D: 93.10, H: 92.90 F1: 93.00	- - -
Önerilen Model	Li (10, 5869) D0(40, 4508)	Veri artırımı	ResNet-101 ile Transfer öğrenme	D: 96.36, K: 96.19, H: 95.91, F1: 96.06 D: 99.63, K: 99.68, H:99.67, F1: 99.68	Test: 220.70 Test: 164.39

Önerilen modellerin performansları, bitki görüntülerindeki zararlıların tanınması alanında literatürde yer alan önceki çalışmalarla karşılaştırılarak kapsamlı bir şekilde analiz edilmiştir. Literatürde farklı bitki zararlısı türleri ve sayıları ile tespiti, sınıflandırması ve segmentasyonu olmak üzere çeşitli uygulama alanlarında çeşitli yöntemler ile bitki görüntülerinden oluşan farklı veri setlerine odaklanan birçok sayıda çalışma bulunmaktadır. Önerilen modellerin iki veri setinde de elde ettiği en yüksek performans, diğer çalışmaların sonuçlarıyla birlikte Tablo 5' te

sunulmuştur. Bu karşılaştırma sürecinde, çalışmalardaki sınıf ve görüntü sayıları, kullanılan veri setleri, sınıflandırma yöntemleri ve sınıflandırma doğruluğu, kesinlik, hassasiyet ve F1 skoru gibi performans ölçütleri gibi çeşitli faktörler dikkate alınmıştır. Önerilen modeller, önceki çalışmalarla karşılaştırıldığında sınıflandırma doğruluğu ve diğer performans metrikleri açısından benzer veya daha üstün bir performans sergilemiştir. Bu sonuçlar, önerilen modellerin bitki zararlısı sınıflandırma konusunda etkili bir çözüm sunduğunu göstermektedir. Ayrıca, bu çalışmada literatürdeki çoğu çalışmadan farklı olarak deneylerin işlem süreleri de verilmiştir. Gelecek çalışmalarda, bitki zararlılarının tespiti ve sınıflandırılması için daha geniş sınıf sayısına sahip çeşitli veri setleri kullanılarak modelin genelleme kabiliyetinin artırılması hedeflenmektedir. Yeni nesil derin öğrenme mimarileri ve gelişmiş transfer öğrenme teknikleri ile performans iyileştirmelerinin yapılması planlanmaktadır.

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Chen, W., Gao, H., Ding, D., Dong, X., Luo, X., 2023. Chili Pepper Pests Recognition Based on Hsv Color Space and Convolutional Neural Networks. In 2023 IEEE 3rd International Conference on Electronic Technology, Communication and Information (ICETCI), pp. 241-245.
- Deng, L., Wang, Y., Han, Z., & Yu, R., 2018. Research on Insect Pest Image Detection and Recognition Based on Bio-Inspired Methods. *Biosystems Engineering*, 169, 139-148.
- 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.
- Li, Y., Wang, H., Dang, L. M., Sadeghi-Niaraki, A., Moon, H., 2020. Crop Pest Recognition in Natural Scenes Using Convolutional Neural Networks. *Computers and Electronics in Agriculture*, 169.
- Maharana, K., Mondal, S., Nemade, B., 2022. A review: Data Pre-Processing and Data Augmentation Techniques. *Global Transitions Proceedings*, 3(1), 91-99.
- Nanni, L., Maguolo, G., Pancino, F., 2020. Insect Pest Image Detection and Recognition Based on Bio-Inspired Methods. *Ecological Informatics*, 57, 101089.
- Qin, X., Zhang, Z., Huang, C., Dehghan, M., Zaiane, O. R., & Jagersand, M., 2020. U2-Net: Going Deeper with Nested U-structure for Salient Object Detection. *Pattern Recognition*, 106, 107404.
- 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.
- 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.
- Thenmozhi, K., Reddy, U. S., 2019. Crop Pest Classification Based on Deep Convolutional Neural Network and Transfer Learning. *Computers and Electronics in Agriculture*, 164, 104906.
- Toscano-Miranda, R., Aguilar, J., Hoyos, W., Caro, M., Trebilcok, A., & Toro, M., 2024. Different Transfer Learning Approaches for Insect Pest Classification in Cotton. *Applied Soft Computing*, 153, 111283.
- Wang, C., Zhang, J., He, J., Luo, W., Yuan, X., Gu, L., 2023. A Two-Stream Network with Complementary Feature Fusion for Pest Image Classification. *Engineering Applications of Artificial Intelligence*, 124, 106563.
- Wu, X., Zhan, C., Lai, Y. K., Cheng, M. M., & Yang, J., 2019. Ip102: A Large-Scale Benchmark Dataset for Insect Pest Recognition. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 8787-8796).
- Xia, D., Chen, P., Wang, B., Zhang, J., Xie, C., 2018. Insect Detection and Classification Based on an Improved Convolutional Neural Network. *Sensors*, 18(12).
- Xiao, B., Ma, J. F., Cui, J. T., 2012. Combined Blur, Translation, Scale and Rotation Invariant Image Recognition by Radon and Pseudo-Fourier-Mellin Transforms. *Pattern Recognition*, 45(1), 314-321.
- Xie, C., Zhang, J., Li, R., Li, J., Hong, P., Xia, J., Chen, P., 2015. Automatic Classification for Field Crop Insects via Multiple-Task Sparse Representation and Multiple-Kernel Learning. *Computers and Electronics in Agriculture*, 119, 123-132.
- Xie, C., Wang, R., Zhang, J., Chen, P., Dong, W., Li, R., Chen, H., 2018. Multi-Level Learning Features for Automatic Classification of Field Crop Pests. *Computers and Electronics in Agriculture*, 152, 233-241.
- Yang, X., Luo, Y., Li, M., Yang, Z., Sun, C., Li, W., 2021a. Recognizing Pests in Field-Based Images by Combining Spatial and Channel Attention Mechanism. *IEEE Access*, 9, 162448-162458.
- Yang, Z., Li, W., Li, M., Yang, X., 2021b. Automatic Greenhouse Pest Recognition Based on Multiple Color Space Features. *International Journal of Agricultural and Biological Engineering*, 14(2), 188-195.