

Klasifikasi Penyakit Tanaman Daun Tomat Menggunakan Transfer Learning

Tuti Andriani*, Muhammad Iqbal, Darmeli Nasution

Pascasarjana, Magister Teknologi Informasi, Universitas Pembangunan Panca Budi, Medan, Indonesia

Email: ¹*tutiandriani9530@email.com, ² wakbalpb@yahoo.co.id, ³darmelinasution@gmail.com

Email Penulis Korespondensi: tutiandriani9530@gmail.com*

Submitted: 12/05/2025; Accepted: 24/06/2025; Published: 30/06/2025

Abstrak—Penyakit daun pada tanaman tomat dapat mengakibatkan penurunan hasil panen secara signifikan dan mengganggu keberlanjutan produksi pertanian. Penelitian ini mengusulkan pendekatan klasifikasi multikelas penyakit daun tomat menggunakan metode transfer learning dengan memanfaatkan arsitektur CNN prelatih DenseNet121 dan DenseNet169. Dataset yang digunakan adalah subset dari PlantVillage, mencakup enam kelas penyakit dan daun sehat, dengan preprocessing berupa augmentasi citra dan normalisasi ukuran. Strategi pelatihan melibatkan dua tahap, yaitu feature extraction dan fine-tuning, dengan optimasi berbasis Adam dan fungsi loss categorical cross-entropy. Hasil evaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score menunjukkan bahwa model DenseNet121 memberikan kinerja terbaik dengan akurasi 96,23%, disusul MobileNetV2 dengan 92,89%. Visualisasi kurva loss dan analisis confusion matrix memperkuat temuan bahwa model dapat melakukan klasifikasi dengan stabil dan akurat, meskipun beberapa kesalahan terjadi pada kelas dengan gejala visual yang mirip. Penelitian ini membuktikan bahwa transfer learning dengan DenseNet, terutama varian 121, efektif dalam mengklasifikasikan berbagai jenis penyakit daun tomat dan dapat diimplementasikan sebagai sistem pendukung diagnosis penyakit tanaman berbasis citra secara otomatis dan efisien.

Kata Kunci: Klasifikasi Citra; Penyakit Daun Tomat; Transfer Learning; DenseNet; Deep Learning Pertanian

Abstract—Leaf diseases in tomato plants can significantly reduce crop yields and threaten agricultural sustainability. This study proposes a multi-class classification approach for tomato leaf diseases using transfer learning with pre-trained CNN architectures, specifically DenseNet121 and DenseNet169. The dataset used is a subset of PlantVillage, consisting of six disease classes and healthy leaves, with preprocessing steps including image augmentation and resizing. The training strategy involves two phases: feature extraction and fine-tuning, optimized using the Adam algorithm and categorical cross-entropy loss function. Evaluation metrics such as accuracy, precision, recall, and F1-score show that the DenseNet121 model achieves the best performance, reaching an accuracy of 96.23%, followed by MobileNetV2 with 92.89%. Loss curves and confusion matrix analysis confirm that the model performs classification tasks with stability and high precision, despite some misclassifications between visually similar disease classes. This study demonstrates that transfer learning with DenseNet—particularly DenseNet121 is effective for automatic and efficient classification of various tomato leaf diseases, offering potential for real-world implementation as a computer vision-based plant disease diagnosis system..

Keywords: Image Classification; Tomato Leaf Disease; Transfer Learning; DenseNet; Agricultural Deep Learning.

1. PENDAHULUAN

Tomat (*Solanum lycopersicum*) adalah salah satu tanaman sayuran yang paling banyak dibudidayakan di seluruh dunia karena nilai gizinya dan keuntungan ekonominya yang tinggi[1]. Namun, budidaya tomat sangat rentan terhadap berbagai penyakit daun seperti penyakit busuk daun (*Alternaria solani*), penyakit busuk daun (*Phytophthora infestans*), bercak daun septoria (*Septoria lycopersici*), bercak bakteri, dan jamur daun[2]. Penyakit-penyakit ini bermanifestasi melalui gejala visual pada daun, yang menyebabkan berkurangnya efisiensi fotosintesis, kesehatan tanaman yang terganggu, dan kehilangan hasil panen yang signifikan[3]. Oleh karena itu, identifikasi dini dan akurat terhadap penyakit-penyakit ini sangat penting untuk produksi tomat yang berkelanjutan. Secara tradisional, identifikasi penyakit pada tanaman tomat sangat bergantung pada inspeksi visual manual yang dilakukan oleh ahli agronomi atau ahli patologi tanaman yang berpengalaman[4]. Namun, pendekatan ini pada dasarnya bersifat subjektif, padat karya, dan tidak praktis untuk memantau perkebunan berskala besar. Selain itu, gejala penyakit yang tidak konsisten di bawah kondisi lingkungan yang berbeda-beda dapat mengurangi akurasi diagnostik[5]. Tantangan-tantangan ini telah memotivasi integrasi visi komputer dan teknik pembelajaran mesin ke dalam domain diagnosis penyakit tanaman. Convolutional Neural Networks (CNN) telah muncul sebagai alat yang ampuh untuk tugas klasifikasi gambar otomatis, termasuk deteksi penyakit tanaman[6]. Namun, melatih CNN dari awal membutuhkan data berlabel dalam jumlah besar dan sumber daya komputasi yang cukup besar. Untuk mengatasi keterbatasan ini, pembelajaran transfer telah menjadi strategi yang diadopsi secara luas, memanfaatkan pengetahuan dari model-model yang telah dilatih sebelumnya dalam skala besar (misalnya, ImageNet) untuk meningkatkan efisiensi pembelajaran pada tugas-tugas spesifik domain dengan data yang terbatas[7]. Di antara berbagai arsitektur CNN, DenseNet (Densely Connected Convolutional Network) telah menunjukkan kinerja yang luar biasa karena kemampuannya untuk memperkuat penyebaran fitur, menggunakan kembali fitur, dan mengurangi jumlah parameter. DenseNet memperkenalkan koneksi langsung antara dua lapisan dengan ukuran peta fitur yang sama, yang membantu mengurangi masalah gradien yang hilang dan meningkatkan generalisasi model[8].

Meskipun berbagai pendekatan berbasis CNN telah berhasil diterapkan untuk klasifikasi penyakit tanaman, sebagian besar penelitian sebelumnya hanya berfokus pada klasifikasi biner antara daun sehat dan daun sakit[9]. Kajian mendalam mengenai klasifikasi multikelas yang mencakup berbagai jenis penyakit daun tomat masih terbatas, khususnya dalam konteks pemanfaatan arsitektur DenseNet melalui strategi transfer learning[10]. Selain itu, penelitian yang secara eksplisit membandingkan kinerja beberapa varian DenseNet dalam mendeteksi gejala penyakit secara otomatis dari citra daun tomat juga belum banyak ditemukan[11]. Kesenjangan ini membuka peluang untuk mengevaluasi keefektifan model pretrained DenseNet dalam konteks klasifikasi multikelas yang lebih kompleks dan aplikatif di lapangan. Sejalan dengan hal tersebut, penelitian ini bertujuan untuk mengevaluasi efektivitas model DenseNet berbasis transfer learning dalam melakukan klasifikasi multikelas terhadap berbagai jenis penyakit daun tanaman tomat. Studi ini akan mengimplementasikan dan membandingkan dua varian arsitektur DenseNet, yaitu DenseNet121 dan DenseNet169, dengan memanfaatkan dataset citra daun tomat dari PlantVillage. Melalui analisis performa menggunakan metrik akurasi, presisi, recall, dan F1-score, penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan sistem deteksi penyakit tanaman berbasis visi komputer yang lebih andal dan efisien.

2. METODOLOGI PENELITIAN

2.1 Dataset

Penelitian ini menggunakan dataset PlantVillage, yaitu dataset open-source yang banyak digunakan dalam penelitian klasifikasi penyakit tanaman. Dari dataset ini, diambil subset khusus yang terdiri dari gambar daun tanaman tomat. Data ini mencakup beberapa kelas penyakit daun, yaitu

1. Early blight (*Alternaria solani*),
2. Late blight (*Phytophthora infestans*),
3. Leaf mold,
4. Septoria leaf spot,
5. Bacterial spot,
6. Daun sehat.

Setiap citra diproses ulang dan diubah ukurannya menjadi 224×224 piksel agar sesuai dengan input standar arsitektur DenseNet. Dataset dibagi menjadi data latih (70%), validasi (15%), dan uji (15%) secara stratified agar distribusi kelas tetap seimbang.

2.2 Arsitektur Model

Dalam upaya meningkatkan akurasi klasifikasi penyakit daun tomat, penelitian ini memanfaatkan pendekatan transfer learning dengan menggunakan dua arsitektur Convolutional Neural Network (CNN) pralatih, yaitu DenseNet121 dan DenseNet169. Kedua model ini dipilih karena kemampuannya yang telah terbukti dalam mengekstraksi fitur visual secara efisien pada berbagai tugas klasifikasi citra. Model-model tersebut diinisialisasi dengan bobot dari dataset ImageNet, sehingga memungkinkan transfer pengetahuan dari domain yang lebih luas ke domain target, yaitu citra daun tomat yang mengandung gejala penyakit. Untuk menyesuaikan model terhadap tugas klasifikasi khusus ini, lapisan klasifikasi bawaan dihapus dan digantikan dengan susunan lapisan baru yang terdiri atas Global Average Pooling untuk mereduksi dimensi fitur secara efisien, Dropout layer dengan tingkat 0.5 untuk mengurangi risiko overfitting, dan Fully Connected layer dengan fungsi aktivasi Softmax yang menyesuaikan jumlah neuron dengan jumlah kelas penyakit daun tomat. Dengan konfigurasi ini, model diharapkan mampu menghasilkan representasi fitur yang relevan dan klasifikasi yang akurat meskipun pada data yang terbatas, sesuai dengan tantangan umum dalam penerapan deep learning pada domain pertanian.

2.3 Strategi Transfer Learning

Dalam penelitian klasifikasi penyakit daun tomat menggunakan transfer learning ini, diterapkan dua strategi utama untuk mengadaptasi model pralatih terhadap dataset target. Strategi pertama adalah feature extraction, di mana seluruh bagian konvolusional dari model pralatih DenseNet121 dan DenseNet169 dibekukan (frozen), sehingga hanya bagian klasifikasi yang dilatih ulang. Pendekatan ini memungkinkan pemanfaatan fitur-fitur umum yang telah dipelajari oleh model dari dataset ImageNet tanpa melakukan perubahan pada representasi awal. Strategi kedua adalah fine-tuning, yaitu setelah pelatihan awal pada bagian klasifikasi, sebagian lapisan bawah dari arsitektur DenseNet dibuka kembali dan dilatih ulang dengan laju pembelajaran rendah. Pendekatan ini bertujuan untuk menyesuaikan representasi fitur agar lebih relevan dengan karakteristik visual daun tomat dan meningkatkan akurasi klasifikasi. Proses pelatihan dilakukan menggunakan loss function categorical cross-entropy, yang sesuai untuk tugas klasifikasi multikelas, dan dioptimalkan dengan Adam optimizer menggunakan laju pembelajaran awal sebesar 0.0001 serta ukuran batch 32. Kombinasi strategi ini diharapkan dapat menghasilkan model yang tidak hanya akurat, tetapi juga mampu melakukan generalisasi dengan baik pada data yang belum pernah dilihat.

2.4 Augmentasi Data

Untuk meningkatkan variasi data latih dan mencegah overfitting, dilakukan augmentasi citra menggunakan modul ImageDataGenerator. Teknik augmentasi meliputi:

1. Rotasi acak hingga 20 derajat,

2. Flip horizontal dan vertikal,
3. Zoom hingga 20%,
4. Penyesuaian kecerahan.

2.5 Lingkungan Eksperimen

Seluruh eksperimen dalam penelitian klasifikasi penyakit daun tomat ini dilakukan menggunakan platform Google Colab dengan dukungan GPU Runtime untuk mempercepat proses pelatihan model. Implementasi model dilakukan dengan menggunakan TensorFlow versi 2.x dan API Keras, yang menyediakan fleksibilitas dan efisiensi dalam membangun serta melatih arsitektur deep learning. Model dilatih selama 25 hingga 50 epoch, tergantung pada performa yang dicapai selama proses pelatihan. Untuk menghindari overfitting dan memastikan efisiensi pelatihan, digunakan teknik early stopping dengan pemantauan terhadap nilai loss pada data validasi. Pendekatan ini memungkinkan proses pelatihan berhenti secara otomatis jika tidak ada peningkatan signifikan dalam performa model, sehingga dapat menghindari pelatihan yang berlebihan dan mempercepat waktu komputasi.

2.6 Metrik Evaluasi

Evaluasi performa model dalam tugas klasifikasi penyakit daun tomat, penelitian ini menggunakan sejumlah metrik evaluasi klasifikasi yang komprehensif. Metrik utama yang digunakan meliputi akurasi, presisi, recall, dan F1-score. Akurasi digunakan untuk mengukur proporsi prediksi yang benar secara keseluruhan, sementara presisi dan recall memberikan gambaran lebih spesifik mengenai kemampuan model dalam mengidentifikasi kelas positif secara tepat dan lengkap. F1-score, sebagai rata-rata harmonik dari presisi dan recall, digunakan untuk menilai keseimbangan antara keduanya, terutama penting dalam kondisi distribusi kelas yang tidak seimbang. Selain itu, dilakukan juga analisis terhadap confusion matrix guna mengamati performa model pada masing-masing kelas serta mengidentifikasi pola-pola kesalahan klasifikasi yang terjadi. Pendekatan evaluasi ini memberikan pemahaman yang lebih menyeluruh terhadap kekuatan dan kelemahan model yang dikembangkan.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil implementasi dan evaluasi dari model klasifikasi penyakit daun tomat yang dikembangkan menggunakan pendekatan transfer learning berbasis arsitektur DenseNet121 dan DenseNet169. Tujuan utama dari analisis ini adalah untuk menguji keefektifan masing-masing model dalam mengklasifikasikan berbagai jenis penyakit daun tomat secara multikelas, serta mengevaluasi sejauh mana strategi augmentasi data dan fine-tuning dapat meningkatkan performa klasifikasi.


3.1 Implementasi Model Transfer Learning DenseNet

Dalam penelitian ini, dua varian arsitektur CNN prelatih, yaitu DenseNet121 dan DenseNet169, diimplementasikan menggunakan pendekatan transfer learning. Kedua model dimodifikasi pada bagian klasifikasinya, kemudian dilatih ulang menggunakan data citra daun tomat dari dataset PlantVillage yang telah diaugmentasi. Model dilatih selama 50 epoch menggunakan optimasi Adam dan fungsi loss categorical cross-entropy. Pelatihan dilakukan dalam dua fase: feature extraction dan fine-tuning. Fase pertama menghasilkan baseline awal untuk klasifikasi, sedangkan fase kedua bertujuan menyempurnakan pembelajaran fitur dengan membuka sebagian layer bawah model. Evaluasi dilakukan menggunakan data uji sebesar 15% dari keseluruhan data yang terbagi secara stratified.

3.2 Visualisasi Kurva Akurasi dan Loss

Evaluasi stabilitas dan efektivitas proses pelatihan model klasifikasi penyakit daun tomat, dilakukan pemantauan terhadap nilai loss pada data pelatihan dan validasi selama 50 epoch. Kurva loss yang ditampilkan pada Gambar 1 menggambarkan dinamika perubahan nilai training loss dan validation loss terhadap jumlah epoch selama proses pelatihan berlangsung. Visualisasi ini memberikan gambaran umum mengenai bagaimana model belajar dari data, serta seberapa baik model mampu melakukan generalisasi terhadap data baru yang belum pernah dilihat sebelumnya.

Kurva ini juga digunakan untuk mendeteksi kemungkinan terjadinya overfitting atau underfitting, serta untuk menilai efektivitas strategi transfer learning dan augmentasi data yang diterapkan. Evaluasi dilakukan secara menyeluruh untuk memastikan bahwa proses pelatihan berjalan secara optimal dan menghasilkan model dengan kemampuan klasifikasi yang handal. Berikut ini adalah analisis lebih lanjut terhadap pola loss yang terlihat pada grafik.



Gambar 1. Loss Curve

Kurva loss ini menunjukkan bahwa proses pelatihan berjalan stabil dan efektif. Model tidak mengalami overfitting maupun underfitting secara signifikan, dan mampu belajar representasi fitur secara bertahap hingga mencapai stabilitas pada sekitar epoch ke-40. Oleh karena itu, model dapat dikatakan siap untuk diterapkan pada data uji maupun aplikasi nyata dalam mendeteksi penyakit daun tomat.

3.3 Hasil Evaluasi Klasifikasi

Tabel 1 menunjukkan performa tiga arsitektur model deep learning yang digunakan untuk klasifikasi penyakit daun tomat, yaitu DenseNet201, DenseNet121, dan MobileNetV2, berdasarkan empat metrik utama: Accuracy, Precision, Recall, dan F1 Score.

Tabel 1. Hasil Evaluasi Model pada Data Uji


Model	Accuracy	Precision	Recall	F1 Score
Densenet 201	0.6763	0.4943	0.4985	0.4935
Densenet 121	0.9623	0.8689	0.8690	0.8688
MobileNetV2	0.9289	0.9295	0.9289	0.9287

Berdasarkan hasil evaluasi, dapat disimpulkan bahwa DenseNet121 memberikan kinerja klasifikasi terbaik secara keseluruhan untuk mendeteksi penyakit daun tomat, dengan akurasi tinggi dan keseimbangan metrik yang solid. Sementara itu, MobileNetV2 juga menunjukkan performa sangat kompetitif dan cocok untuk implementasi ringan. Sebaliknya, DenseNet201 tidak direkomendasikan dalam konteks dataset ini karena performanya jauh lebih rendah, yang mungkin disebabkan oleh kompleksitas model yang berlebihan terhadap ukuran dan keragaman data yang tersedia. Penelitian ini menunjukkan bahwa arsitektur model yang lebih dalam tidak selalu menjamin hasil yang lebih baik, melainkan perlu disesuaikan dengan karakteristik data dan tujuan aplikasi.

3.4 Analisis Confusion Matrix

Gambar 2 menampilkan confusion matrix dari hasil klasifikasi penyakit daun tomat menggunakan model deep learning. Terdapat 10 kelas yang merepresentasikan jenis penyakit daun tomat dan kondisi daun sehat. Matriks ini menunjukkan distribusi prediksi model terhadap label sebenarnya, dengan baris merepresentasikan label sebenarnya (true label) dan kolom menunjukkan label yang diprediksi (predicted label). Dari matriks tersebut terlihat bahwa sebagian besar prediksi berada pada diagonal utama, yang berarti model berhasil mengklasifikasikan sebagian besar data secara akurat. Misalnya, kelas Tomato_Bacterial_spot memiliki 212 prediksi benar dari total data yang diuji, dan Tomato_YellowLeaf_Curl_Virus berhasil diprediksi dengan benar

sebanyak 321 kali. Demikian pula, Tomato_Late_blight dan Tomato_healthy menunjukkan performa yang sangat baik dengan nilai prediksi benar yang tinggi, yaitu 188 dan 160 secara berturut-turut. Beberapa kesalahan klasifikasi masih terjadi, misalnya pada Tomato_Early_blight yang sering diklasifikasikan secara salah menjadi Tomato_Late_blight atau Tomato_Septoria_leaf_spot, yang menunjukkan kemiripan fitur antar kelas tersebut.



Gambar 2. Confusion Matrix

Model klasifikasi menunjukkan performa yang sangat baik dengan akurasi tinggi pada sebagian besar kelas. Kesalahan klasifikasi yang terjadi sebagian besar berada pada kelas-kelas dengan gejala visual yang serupa, seperti Early Blight dan Late Blight, yang merupakan tantangan umum dalam deteksi penyakit tanaman berbasis citra. Namun, secara keseluruhan, confusion matrix ini membuktikan bahwa model memiliki kemampuan yang kuat dalam mengidentifikasi berbagai penyakit daun tomat secara otomatis.

3.5 Pembahasan Hasil

Hasil evaluasi menunjukkan bahwa arsitektur DenseNet121 yang diterapkan melalui pendekatan transfer learning memberikan performa klasifikasi terbaik dalam mendeteksi penyakit daun tomat secara multikelas. Model ini mampu mencapai akurasi tinggi sebesar 96,23%, dengan nilai presisi, recall, dan F1-score yang seimbang, menunjukkan stabilitas dan keandalan dalam mengenali pola visual dari berbagai jenis penyakit. Keunggulan DenseNet121 dibandingkan varian lain seperti DenseNet201 dan MobileNetV2 terletak pada efisiensi arsitekturnya dalam mengalirkan informasi antar layer, sehingga dapat menangkap fitur penting meskipun data yang tersedia terbatas. Sementara itu, MobileNetV2 juga menunjukkan kinerja yang kompetitif dan potensial untuk aplikasi ringan, khususnya pada perangkat dengan sumber daya terbatas. Sebaliknya, performa rendah dari DenseNet201 diduga berasal dari kompleksitas model yang berlebihan terhadap ukuran dataset yang relatif kecil, yang justru menyebabkan overfitting.

Strategi pelatihan dua tahap feature extraction dan fine-tuning berhasil meningkatkan kemampuan generalisasi model. Feature extraction memungkinkan model mempertahankan pengetahuan awal dari pelatihan pada ImageNet, sementara fine-tuning menyelaraskan representasi fitur agar lebih sesuai dengan karakteristik visual

daun tomat. Teknik augmentasi data juga terbukti efektif dalam menambah keragaman data latih, memperkuat kemampuan model menghadapi variasi citra di dunia nyata, dan mencegah overfitting. Selain itu, analisis confusion matrix menunjukkan bahwa kesalahan klasifikasi umumnya terjadi pada kelas penyakit dengan gejala visual yang mirip, seperti antara Early Blight dan Late Blight. Hal ini menandakan bahwa meskipun performa keseluruhan tinggi, tantangan tetap ada dalam membedakan penyakit yang secara morfologis hampir serupa. Oleh karena itu, pengembangan model selanjutnya dapat mengintegrasikan perhatian spasial atau mekanisme segmentasi lokal untuk meningkatkan sensitivitas terhadap detail visual yang lebih halus. Secara keseluruhan, pendekatan ini menunjukkan bahwa transfer learning berbasis DenseNet sangat menjanjikan untuk aplikasi diagnosis penyakit tanaman secara otomatis dan praktis di sektor pertanian.

4. KESIMPULAN

Hasil implementasi dan evaluasi model, dapat disimpulkan bahwa pendekatan transfer learning menggunakan arsitektur DenseNet, khususnya DenseNet121, sangat efektif dalam melakukan klasifikasi multikelas terhadap penyakit daun tomat. Model ini menunjukkan kinerja yang unggul dengan akurasi tinggi dan nilai presisi, recall, serta F1-score yang seimbang, mengindikasikan kemampuan generalisasi yang baik meskipun pada data terbatas. Strategi pelatihan bertahap yang terdiri dari feature extraction dan fine-tuning terbukti mampu mengadaptasi model pralatih dengan optimal terhadap karakteristik visual dari citra daun tomat. Penerapan teknik augmentasi citra juga memberikan kontribusi positif dengan meningkatkan keragaman data latih dan mengurangi risiko overfitting. Selain itu, analisis confusion matrix memperlihatkan bahwa sebagian besar kelas berhasil diklasifikasikan dengan baik, meskipun terdapat tantangan pada kelas dengan gejala visual yang serupa. Secara keseluruhan, penelitian ini membuktikan bahwa pemanfaatan DenseNet berbasis transfer learning merupakan solusi yang menjanjikan untuk pengembangan sistem diagnosis penyakit tanaman berbasis citra secara otomatis, efisien, dan akurat, serta memiliki potensi tinggi untuk diimplementasikan dalam skenario pertanian dunia nyata.

REFERENCES

- [1] W. Bihon, K. E. Ognakossan, J. B. Tignegre, P. Hanson, K. Ndiaye, and R. Srinivasan, "Evaluation of Different Tomato (*Solanum lycopersicum* L.) Entries and Varieties for Performance and Adaptation in Mali, West Africa," *Horticulturae*, vol. 8, no. 7, 2022, doi: 10.3390/horticulturae8070579.
- [2] D. R. Panthee, A. Pandey, and R. Paudel, "Multiple Foliar Fungal Disease Management in Tomatoes: A Comprehensive Approach," *Int. J. Plant Biol.*, vol. 15, no. 1, pp. 69–93, 2024, doi: 10.3390/ijpb15010007.
- [3] V. Ghimirey, J. Chaurasia, and S. Marahatta, "PLANT NUTRITION DISORDERS : INSIGHTS FROM CLINIC ANALYSES AND Agriculture Extension in Developing Countries PLANT NUTRITION DISORDERS: INSIGHTS FROM CLINIC ANALYSES AND THEIR," no. May, 2024, doi: 10.26480/aedc.01.2024.09.17.
- [4] A. Abbas *et al.*, "Drones in Plant Disease Assessment, Efficient Monitoring, and Detection: A Way Forward to Smart Agriculture," *Agronomy*, vol. 13, no. 6, 2023, doi: 10.3390/agronomy13061524.
- [5] M. A. John, I. Bankole, O. Ajayi-Moses, T. Ijila, T. Jeje, and P. Lalit, "Relevance of Advanced Plant Disease Detection Techniques in Disease and Pest Management for Ensuring Food Security and Their Implication: A Review," *Am. J. Plant Sci.*, vol. 14, no. 11, pp. 1260–1295, 2023, doi: 10.4236/ajps.2023.1411086.
- [6] T. Shi *et al.*, "Recent advances in plant disease severity assessment using convolutional neural networks," *Sci. Rep.*, vol. 13, no. 1, pp. 1–13, 2023, doi: 10.1038/s41598-023-29230-7.
- [7] P. Yan *et al.*, "A Comprehensive Survey of Deep Transfer Learning for Anomaly Detection in Industrial Time Series: Methods, Applications, and Directions," *IEEE Access*, vol. 12, no. January, pp. 3768–3789, 2024, doi: 10.1109/ACCESS.2023.3349132.
- [8] Y. Hou, Z. Wu, X. Cai, and T. Zhu, "The application of improved densenet algorithm in accurate image recognition," *Sci. Rep.*, vol. 14, no. 1, pp. 1–14, 2024, doi: 10.1038/s41598-024-58421-z.
- [9] J. Lu, L. Tan, and H. Jiang, "Review on convolutional neural network (CNN) applied to plant leaf disease classification," *Agric.*, vol. 11, no. 8, pp. 1–18, 2021, doi: 10.3390/agriculture11080707.
- [10] W. B. Demilie, "Plant disease detection and classification techniques: a comparative study of the performances," *J. Big Data*, vol. 11, no. 1, 2024, doi: 10.1186/s40537-023-00863-9.
- [11] S. Albahli and M. Nawaz, "DCNet: DenseNet-77-based CornerNet model for the tomato plant leaf disease detection and classification," *Front. Plant Sci.*, vol. 13, no. September, pp. 1–19, 2022, doi: 10.3389/fpls.2022.957961.