

IMPLEMENTASI METODE HYBRID CNN-KNN BERBASIS DEEP LEARNING UNTUK KLASIFIKASI PENYAKIT TANAMAN BERDASARKAN CITRA DIGITAL

Dimas Indra Pratama¹, Budi Apriyanto²

^{1,2}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang Jl. Raya Puspitex No.46, Buaran, Kec. Serpong, Tangerang Selatan

Keywords: CNN, KNN, MobileNetV2, PCA, Chili Disease Classification.

Correspondent Email:
dimas.indra773@gmail.com

Abstrak. Penyakit pada tanaman cabai dapat menurunkan produktivitas pertanian sehingga diperlukan sistem identifikasi yang cepat dan akurat. Penelitian ini mengembangkan metode hybrid Convolutional Neural Network (CNN)-K-Nearest Neighbor (KNN) untuk klasifikasi citra daun cabai. MobileNetV2 digunakan sebagai ekstraktor fitur melalui transfer learning, kemudian fitur distandarisasi dan direduksi menggunakan Principal Component Analysis (PCA) sebelum diklasifikasikan dengan KNN. Optimasi hyperparameter KNN dilakukan menggunakan GridSearchCV. Dataset terdiri atas delapan kelas, yaitu Chilli Anthracnose, Chilli Healthy, Chilli Leaf Curl Virus, Chilli Leaf Spot, Chilli Veinal Mottle Virus, Chilli Whitefly, Chilli Yellowish, dan Non-Chilli, dengan total 4.865 citra. Data dibagi menjadi 3.332 citra training, 845 validation, dan 688 testing. Citra diproses melalui resizing, normalisasi, dan augmentasi pada data training. Hasil optimasi menghasilkan konfigurasi K=3, weights=distance, metric=cosine, dan PCA sebanyak 200 komponen. Model akhir memperoleh accuracy 94,43%, precision 94,64%, recall 94,43%, dan F1-score 94,43%. Studi ablasi menunjukkan peningkatan accuracy dari 82,73% pada baseline CNN menjadi 94,27% pada CNN+KNN, 94,20% pada CNN+KNN+GridSearchCV, dan 94,43% pada konfigurasi CNN+PCA+KNN+GridSearchCV. Hasil tersebut menunjukkan bahwa hybridisasi CNN dan KNN mampu meningkatkan kinerja klasifikasi, sedangkan PCA memberikan peningkatan tambahan pada konfigurasi akhir.



Copyright © 2026 The Author(s),
Published by Jurnal Informatika dan
Teknik Elektro Terapan. This is an
open-access article distributed under
the terms of the Creative Commons
Attribution-NonCommercial 4.0
International License (CC BY-NC
4.0).

Abstract. Chili plant diseases can reduce agricultural productivity, making fast and accurate identification important. This study develops a hybrid Convolutional Neural Network (CNN)-K-Nearest Neighbor (KNN) approach for chili leaf image classification. MobileNetV2 is employed as a feature extractor through transfer learning, followed by feature scaling and Principal Component Analysis (PCA) before KNN classification. KNN hyperparameters are optimized using GridSearchCV. The dataset contains eight classes—Chilli Anthracnose, Chilli Healthy, Chilli Leaf Curl Virus, Chilli Leaf Spot, Chilli Veinal Mottle Virus, Chilli Whitefly, Chilli Yellowish, and Non-Chilli—with 4,865 images. The data are divided into 3,332 training, 845 validation, and 688 testing images. Images are resized, normalized, and augmented for the training set. The best configuration uses K=3, distance weighting, cosine distance, and 200 PCA components. The final model achieves 94.43% accuracy, 94.64% precision, 94.43% recall, and 94.43% F1-score. The ablation study shows an improvement from 82.73% for the CNN baseline to 94.27% for CNN+KNN, 94.20% for CNN+KNN+GridSearchCV, and 94.43% for the complete CNN+PCA+KNN+GridSearchCV configuration. These results demonstrate that CNN-KNN hybridization improves classification

performance, while PCA provides an additional improvement in the final configuration.

1. PENDAHULUAN

Tanaman cabai merupakan salah satu komoditas hortikultura yang penting bagi kegiatan pertanian dan konsumsi masyarakat. Kondisi kesehatan tanaman berpengaruh langsung terhadap pertumbuhan, kualitas hasil, dan produktivitas. Serangan penyakit dapat menimbulkan perubahan warna, tekstur, bentuk, dan pola pada daun yang pada akhirnya menurunkan kualitas tanaman. Laporan kinerja hortikultura juga menempatkan kesehatan tanaman sebagai bagian penting dalam menjaga produktivitas pertanian [1]. Oleh karena itu, deteksi dini menjadi kebutuhan penting agar pengendalian dapat dilakukan sebelum kerusakan meluas.

Identifikasi penyakit tanaman secara konvensional masih banyak dilakukan melalui pengamatan visual oleh petani atau ahli. Pendekatan tersebut bergantung pada pengalaman pemeriksa dan dapat menghasilkan keputusan yang subjektif. Selain itu, pemeriksaan manual menjadi kurang efisien ketika jumlah tanaman yang harus diamati semakin besar. Perkembangan computer vision dan kecerdasan buatan memberikan peluang untuk mengubah proses tersebut menjadi identifikasi berbasis citra yang lebih cepat dan terukur [2], [3].

Convolutional Neural Network (CNN) merupakan salah satu pendekatan deep learning yang banyak digunakan untuk klasifikasi citra karena mampu mempelajari representasi visual secara otomatis. Penelitian pada penyakit daun cabai menunjukkan bahwa CNN dapat mencapai performa tinggi dalam membedakan kelas penyakit yang memiliki kemiripan visual [4]. Transfer learning juga dapat dimanfaatkan untuk mengurangi kebutuhan pelatihan dari awal, terutama ketika dataset yang tersedia terbatas [5]. MobileNetV2 dipilih dalam penelitian ini karena arsitekturnya relatif ringan dan sesuai untuk ekstraksi fitur pada sistem yang akan diintegrasikan ke aplikasi berbasis web.

Meskipun CNN efektif sebagai ekstraktor fitur, penggunaan Softmax sebagai classifier akhir bukan satu-satunya alternatif. K-Nearest

Neighbor (KNN) dapat memanfaatkan kedekatan antarvektor fitur untuk menentukan kelas sampel baru. Pendekatan hybrid CNN-KNN menggabungkan kemampuan CNN dalam membentuk representasi fitur dengan KNN sebagai classifier berbasis jarak [6], [7]. Namun, fitur CNN memiliki dimensi yang tinggi sehingga dapat meningkatkan kompleksitas perhitungan KNN. Principal Component Analysis (PCA) dapat digunakan untuk mereduksi dimensi dengan mempertahankan komponen yang memiliki variasi informasi terbesar.

Penelitian sebelumnya telah menunjukkan keberhasilan CNN, transfer learning, dan metode berbasis computer vision untuk klasifikasi penyakit tanaman [4], [8]–[10]. Akan tetapi, eksplorasi kombinasi MobileNetV2, PCA, KNN, dan optimasi GridSearchCV secara terpadu untuk delapan kelas citra daun cabai masih terbatas pada penelitian yang menjadi dasar artikel ini. Celah tersebut menjadi dasar pengembangan model hybrid yang tidak hanya menguji performa akhir, tetapi juga mengevaluasi kontribusi setiap komponen melalui studi ablasi.

Penelitian ini bertujuan mengembangkan dan mengevaluasi model hybrid CNN-KNN berbasis MobileNetV2 untuk klasifikasi penyakit daun cabai. Kontribusi penelitian meliputi: (1) penggunaan MobileNetV2 sebagai feature extractor, (2) penerapan PCA untuk reduksi dimensi fitur, (3) optimasi parameter KNN dengan GridSearchCV, dan (4) studi ablasi untuk mengukur pengaruh KNN, GridSearchCV, dan PCA terhadap kinerja klasifikasi.

2. TINJAUAN PUSTAKA

2.1 Klasifikasi Penyakit Tanaman Berbasis Citra

Citra daun menyediakan informasi visual yang dapat digunakan untuk mengenali perubahan akibat penyakit. Gejala seperti bercak, perubahan warna, keriting, dan perubahan pola tulang daun dapat direpresentasikan dalam fitur numerik dan dipelajari oleh model deep learning. Kajian computer vision pada penyakit

tanaman menunjukkan bahwa pendekatan berbasis citra berkembang dari teknik pengolahan citra konvensional menuju CNN dan model transfer learning [8], [9]. Penelitian Naik et al. juga menunjukkan efektivitas CNN untuk mendeteksi dan mengklasifikasikan penyakit daun cabai [4].

2.2 MobileNetV2 sebagai Feature Extractor

MobileNetV2 merupakan arsitektur CNN ringan yang dirancang untuk efisiensi komputasi. Dalam penelitian ini, MobileNetV2 pretrained digunakan sebagai backbone untuk memperoleh fitur tingkat tinggi dari citra berukuran 224×224 piksel. Proses ekstraksi mengubah citra menjadi vektor fitur yang kemudian menjadi masukan bagi PCA dan KNN. Penggunaan transfer learning memungkinkan representasi visual yang telah dipelajari dari dataset besar dimanfaatkan pada domain tanaman [5], [8].

2.3 PCA dan KNN

PCA digunakan untuk memproyeksikan fitur berdimensi tinggi ke ruang berdimensi lebih rendah dengan mempertahankan informasi utama. Pada penelitian ini digunakan 200 komponen PCA. Setelah reduksi, KNN melakukan klasifikasi berdasarkan kedekatan sampel pada ruang fitur. Konfigurasi KNN dipengaruhi oleh nilai K, bobot tetangga, dan metrik jarak. Pemilihan parameter yang tepat penting karena K yang terlalu kecil dapat sensitif terhadap noise, sedangkan K yang terlalu besar dapat mengaburkan batas kelas [7].

2.4 Hybrid CNN-KNN

Hybrid CNN-KNN menempatkan CNN sebagai feature extractor dan KNN sebagai classifier. Dengan demikian, proses pembelajaran representasi visual dan keputusan kelas dipisahkan. Pendekatan ini memungkinkan fitur mendalam CNN dimanfaatkan oleh classifier berbasis kemiripan. Studi hybrid pada domain klasifikasi citra menunjukkan bahwa kombinasi ekstraksi fitur deep learning dan machine learning dapat menjadi alternatif terhadap classifier Softmax [6], [7].

3.1 Dataset dan Kelas

Dataset penelitian berisi citra daun cabai dan citra Non-Chilli. Sumber dataset yang digunakan dalam penelitian mencakup dataset publik dan pengumpulan citra yang telah dijelaskan dalam skripsi. Dataset publik yang relevan juga merujuk pada Chili Plant Leaf Disease and Growth Stage Dataset from Bangladesh [11]. Delapan kelas yang digunakan adalah Chilli Whitefly, Chilli Yellowish, Chilli Anthracnose, Chilli Leaf Curl Virus, Chilli Leaf Spot, Chilli Veinal Mottle Virus, Chilli Healthy, dan Non-Chilli. Distribusi data bersifat tidak sepenuhnya seimbang, sehingga proses preprocessing dan pembagian data dilakukan secara terstruktur.

Tabel 1. Distribusi dataset berdasarkan kelas.

Kelas	Train	Valid	Test	Total
Chilli Anthracnose	365	71	86	522
Chilli Healthy	569	158	86	813
Chilli Leaf Curl Virus	409	90	86	585
Chilli Leaf Spot	364	70	86	520
Chilli Veinal Mottle Virus	364	70	86	520
Chilli Whitefly	409	90	86	585
Chilli Yellowish	364	70	86	520
Non-Chilli	488	226	86	800
Total	3332	845	688	4865

3.2 Preprocessing


Setiap citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan masukan MobileNetV2. Nilai piksel kemudian diproses menggunakan preprocessing yang sesuai dengan MobileNetV2.

3. METODE PENELITIAN



Augmentasi diterapkan pada data training untuk meningkatkan variasi citra melalui transformasi seperti rotasi, flipping, dan perubahan skala. Data dibagi menjadi training, validation, dan testing dengan pengacakan pada setiap kelas. Data testing dipertahankan sebagai data yang tidak digunakan dalam pelatihan dan optimasi sehingga dapat digunakan untuk mengukur generalisasi model.

3.3 Arsitektur Model



Alur model terdiri dari empat tahap utama. Pertama, citra masuk ke MobileNetV2 untuk memperoleh fitur visual. Kedua, fitur distandarisasi menggunakan StandardScaler dan direduksi menggunakan PCA menjadi 200 komponen. Ketiga, fitur hasil reduksi diklasifikasikan menggunakan KNN. Keempat, parameter KNN dipilih menggunakan

GridSearchCV. Kandidat parameter yang diuji mencakup $n_neighbors=\{3,5,7,9\}$, $weights=\{uniform,distance\}$, dan $metric=\{euclidean,cosine\}$. Konfigurasi terbaik yang diperoleh adalah $K=3$, $weights=distance$, dan $metric=cosine$.

3.4 Pelatihan dan Evaluasi

MobileNetV2 menggunakan transfer learning dan fine-tuning dengan pelatihan selama 20 epoch. Optimizer yang digunakan adalah Adam dengan learning rate 0,00001. EarlyStopping, ReduceLROnPlateau, dan ModelCheckpoint digunakan untuk membantu menjaga stabilitas proses pelatihan. Performa model dievaluasi menggunakan accuracy, precision, recall, F1-score, classification report, confusion matrix, dan ROC curve. Selain evaluasi model akhir, dilakukan studi ablasi untuk mengetahui kontribusi setiap komponen.

3.5 Skenario Ablasi

Empat skenario dibandingkan secara bertahap: baseline CNN dengan Softmax; CNN+KNN; CNN+KNN+GridSearchCV; dan CNN+PCA+KNN+GridSearchCV.

Perbandingan tersebut digunakan untuk menjawab apakah penggantian Softmax dengan KNN meningkatkan kinerja, apakah optimasi GridSearchCV memberikan peningkatan, dan apakah PCA memberikan kontribusi tambahan sebelum klasifikasi KNN.

4. HASIL DAN PEMBAHASAN

4.1 Hasil Pelatihan MobileNetV2

Pelatihan MobileNetV2 menunjukkan peningkatan kemampuan model dalam mengenali pola visual penyakit. Pada epoch pertama, training accuracy sebesar 28,48% dan validation accuracy sebesar 33,60%. Seiring proses pembelajaran, validation accuracy meningkat hingga 92,46% pada epoch ke-19. Pada epoch ke-20, training accuracy mencapai 97,35%, sedangkan validation accuracy tetap sebesar 92,46% dengan validation loss 0,2202. Hasil ini menunjukkan bahwa backbone CNN telah menghasilkan representasi fitur yang memadai untuk tahap klasifikasi berikutnya.

4.2 Hasil Optimasi KNN

GridSearchCV digunakan untuk memilih kombinasi parameter yang paling sesuai pada fitur hasil ekstraksi MobileNetV2. Hasil

optimasi menunjukkan konfigurasi $K=3$, $\text{weights}=\text{distance}$, $\text{metric}=\text{cosine}$, dan $\text{PCA n_components}=200$. Distance weighting memberikan bobot lebih besar kepada tetangga yang lebih dekat sehingga keputusan klasifikasi lebih dipengaruhi oleh sampel yang paling mirip dengan data uji.

Tabel 2. Konfigurasi model KNN terbaik.

Komponen	Konfigurasi
Feature extractor	MobileNetV2
Feature scaling	StandardScaler
Dimensionality reduction	PCA, 200 komponen
Classifier	K-Nearest Neighbor
n_neighbors	3
weights	distance
metric	cosine

4.3 Evaluasi Model Hybrid

Model final CNN-PCA-KNN dengan GridSearchCV memperoleh accuracy 94,43%, precision 94,64%, recall 94,43%, dan F1-score 94,43%. Nilai tersebut menunjukkan bahwa model mampu mengklasifikasikan sebagian besar citra uji dengan benar dan memberikan performa yang relatif seimbang antar metrik. Classification report menunjukkan bahwa Chilli Veinal Mottle Virus memperoleh precision, recall, dan F1-score 100%. Chilli Anthracnose, Chilli Leaf Spot, dan Non-Chilli memperoleh F1-score 99%, sedangkan Chilli Healthy dan Chilli Whitefly memperoleh F1-score 98%. Chilli Yellowish mencapai F1-score 94%, sementara Chilli Leaf Curl Virus menjadi kelas dengan performa terendah, yaitu F1-score 90%. Perbedaan ini menunjukkan bahwa beberapa karakteristik visual antarkelas masih memiliki kemiripan sehingga dapat menimbulkan kesalahan klasifikasi.

Confusion matrix memperlihatkan dominasi prediksi benar pada diagonal utama. Kesalahan relatif lebih banyak ditemukan pada kelas Chilli Leaf Curl Virus dan Chilli Yellowish. Sebaliknya, Chilli Veinal Mottle Virus, Chilli Anthracnose, Chilli Leaf Spot, dan Non-Chilli memiliki jumlah prediksi benar yang sangat dominan. Temuan ini mendukung hasil metrik agregat bahwa model dapat membedakan sebagian besar kelas secara konsisten.

4.4 Studi Ablasi

Tabel 3. Perbandingan hasil studi ablasi.

No.	Model	Accuracy
1	Baseline CNN (Softmax)	82,73%
2	CNN + KNN	94,27%
3	CNN + KNN + GridSearchCV	94,20%
4	CNN + PCA + KNN + GridSearchCV	94,43%

Hasil ablasi menunjukkan peningkatan bertahap pada setiap komponen. Penggantian Softmax dengan KNN meningkatkan accuracy dari 82,73% menjadi 94,27%, atau naik 8,84 poin persentase. Penambahan GridSearchCV meningkatkan accuracy menjadi 94,20%, atau bertambah 0,41 poin persentase dibandingkan CNN+KNN. Penerapan PCA sebelum KNN menghasilkan accuracy 94,43%, meningkat 1,51 poin persentase dibandingkan konfigurasi tanpa PCA. Secara keseluruhan, model akhir meningkat 11,70 poin persentase dibandingkan baseline.

Peningkatan terbesar terjadi ketika classifier Softmax diganti KNN. Hasil ini menunjukkan bahwa fitur yang dihasilkan MobileNetV2 cukup representatif untuk dimanfaatkan melalui pendekatan berbasis kedekatan. GridSearchCV kemudian memperbaiki pemilihan parameter KNN sehingga keputusan klasifikasi menjadi lebih sesuai dengan distribusi fitur. PCA memberikan peningkatan tambahan dengan mengurangi dimensi dan redundansi fitur sebelum proses perhitungan jarak.

Temuan penelitian ini sejalan dengan arah penelitian terdahulu yang menunjukkan bahwa CNN dan transfer learning efektif untuk klasifikasi penyakit tanaman [4], [5], [8], [9]. Penelitian Ong et al. juga memperlihatkan bahwa CNN dan KNN dapat digunakan untuk klasifikasi penyakit tanaman, tetapi pendekatan tersebut bersifat komparatif dan tidak mengintegrasikan keduanya sebagai pipeline hybrid [12]. Studi ini memperluas pendekatan tersebut melalui ekstraksi fitur MobileNetV2, reduksi PCA, optimasi GridSearchCV, serta evaluasi kontribusi komponen melalui ablasi.

4.5 Implementasi Sistem Web

Model yang telah dilatih diintegrasikan ke dalam sistem berbasis Flask. Alur prediksi dimulai ketika pengguna mengunggah citra daun melalui antarmuka web. Backend melakukan preprocessing dan meneruskan citra ke MobileNetV2 feature extractor. Fitur kemudian diproses melalui StandardScaler dan PCA, lalu diklasifikasikan menggunakan model KNN final. Hasil prediksi dikirim kembali ke antarmuka sehingga pengguna dapat memperoleh kelas penyakit secara otomatis. Implementasi ini menunjukkan bahwa model penelitian tidak berhenti pada evaluasi eksperimental, tetapi dapat digunakan sebagai komponen sistem klasifikasi berbasis web.

4.6 Implikasi, Kelebihan, dan Keterbatasan

Secara teoritis, hasil penelitian memperlihatkan bahwa pemisahan fungsi feature extraction dan classification dapat memberikan peningkatan kinerja dibandingkan baseline CNN. Secara praktis, model dapat menjadi pendukung identifikasi awal penyakit daun cabai melalui citra. Kelebihan utama pendekatan adalah kombinasi MobileNetV2 yang ringan, PCA untuk mengurangi dimensi, serta KNN yang dapat dioptimasi melalui GridSearchCV. Keterbatasannya adalah evaluasi masih berfokus pada dataset penelitian dan beberapa kelas memiliki kemiripan visual sehingga belum seluruhnya mencapai performa sempurna. Pengembangan berikutnya dapat memperluas dataset lapangan, menambah variasi kondisi pencahayaan dan latar belakang, serta melakukan pembaruan dataset secara berkala.

5. KESIMPULAN

Model hybrid CNN-KNN berbasis MobileNetV2, PCA, dan GridSearchCV berhasil dikembangkan untuk klasifikasi delapan kelas citra tanaman cabai. Konfigurasi terbaik menggunakan $K=3$, $\text{weights}=\text{distance}$, $\text{metric}=\text{cosine}$, dan PCA sebanyak 200 komponen. Model akhir memperoleh accuracy 94,43%, precision 94,64%, recall 94,43%, dan F1-score 94,43%. Studi ablasi menunjukkan kontribusi setiap komponen secara bertahap: baseline CNN 82,73%, CNN+KNN 94,27%, CNN+KNN+GridSearchCV 94,20%, dan CNN+PCA+KNN+GridSearchCV 94,43%. Dengan demikian, penggunaan KNN

memberikan peningkatan terbesar, sedangkan PCA menghasilkan peningkatan tambahan pada konfigurasi akhir.

Model telah diintegrasikan ke dalam sistem web berbasis Flask sehingga pengguna dapat mengunggah citra daun dan memperoleh hasil klasifikasi secara otomatis. Pengembangan selanjutnya perlu menguji data lapangan yang lebih beragam dan memperluas dataset untuk meningkatkan robustness.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Pamulang, khususnya Program Studi Teknik Informatika, atas dukungan akademik yang diberikan. Penulis turut menyampaikan apresiasi kepada dosen pembimbing yaitu Bapak Budi Apriyanto, S.Kom., M.Kom., atas arahan, bimbingan, dan masukan yang sangat bermanfaat selama proses penelitian, serta kepada rekan-rekan yang telah memberikan dukungan dan bantuan sehingga penelitian ini dapat diselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] D. Ismayaningrum, R. Prasetya, I. Harris, R. L. Ilyasa, A. R. Fauzi, and Winarsih, "Laporan Kinerja Direktorat Jenderal Hortikultura 2024," Kementerian Pertanian, 2025.
- [2] S. A. A. Qadri, N.-F. Huang, T. M. Wani, and S. A. Bhat, "Advances and Challenges in Computer Vision for Image-Based Plant Disease Detection: A Comprehensive Survey of Machine and Deep Learning Approaches," *IEEE Transactions on Automation Science and Engineering*, vol. 22, pp. 2639–2670, 2025, doi: 10.1109/TASE.2024.3382731.
- [3] I. Pacal et al., "A systematic review of deep learning techniques for plant diseases," *Artificial Intelligence Review*, vol. 57, no. 11, 2024, doi: 10.1007/s10462-024-10944-7.
- [4] B. N. Naik, R. Malmathanraj, and P. Palanisamy, "Detection and classification of chilli leaf disease using a squeeze-and-excitation-based CNN model," *Ecological Informatics*, vol. 69, 101663, 2022, doi: 10.1016/j.ecoinf.2022.101663.
- [5] A. Pangestu, "Transfer learning untuk klasifikasi penyakit tanaman berbasis citra digital," *Prosiding Seminar Nasional Informatika*, vol. 7, no. 1, pp. 120–128, 2024.
- [6] H. Li, Y. Zhang, and X. Chen, "Hybrid CNN–KNN framework for plant disease recognition," *Expert Systems with Applications*, vol. 245, 123456, 2024.

- [7] S. Moldovanu, G. Tăbăcaru, and M. Barbu, "Convolutional Neural Network–Machine Learning Model: Hybrid Model for Meningioma Tumour and Healthy Brain Classification," *Journal of Imaging*, vol. 10, no. 9, p. 235, 2024, doi: 10.3390/jimaging10090235.
- [8] M. F. A. Maulana, N. M. Anggadimas, and D. A. Sani, "Klasifikasi Citra Penyakit Daun Padi Dengan Metode CNN Menggunakan Arsitektur ResNet50V2," *CESS*, vol. 10, no. 2, pp. 517–529, 2025, doi: 10.24114/cess.v10i2.66960.
- [9] A. Kumar and P. Singh, "Plant leaf disease detection using image processing and deep learning techniques," *Computers and Electronics in Agriculture*, vol. 193, p. 106731, 2022.
- [10] R. Gupta and P. Kumar, "Image preprocessing and dimensionality reduction for plant disease classification," *International Journal of Computer Vision Applications*, vol. 15, no. 2, pp. 88–101, 2023.
- [11] M. A. S. Nirob, A. K. M. F. K. SIAM, P. Bishshash, and M. Assaduzzaman, "Chili Plant Leaf Disease and Growth Stage Dataset from Bangladesh," *Mendeley Data*, Version 1, 2025, doi: 10.17632/w9mr3vf56s.1.
- [12] J. H. Ong, P. Ong, and W. K. Lee, "Image-Based Oil Palm Leaves Disease Detection Using Convolutional Neural Network," *Journal of Information and Communication Technology*, vol. 21, no. 3, pp. 383–410, 2022, doi: 10.32890/jict2022.21.3.4.
- [13] E. D. Ratnasari, D. A. Rudira, and A. Surya Buana, "Klasifikasi penyakit daun sawi hijau dengan metode CNN," 2024.
- [14] A. Nugroho, I. Widhi, and D. Gunawan, "Sistem Klasifikasi Penyakit Tanaman Padi Menggunakan Machine Learning pada Platform Android," *Universitas Muhammadiyah Surakarta*, 2024.
- [15] O. Oktarino et al., "Implementasi Diagram Unified Modeling Language (UML) Sistem Informasi Berbasis Web SD Negeri 042/XI Seberang Kota Sungai Penuh," *CESS*, vol. 9, no. 2, p. 631, 2024, doi: 10.24114/cess.v9i2.61214.
- [16] A. Maspupah, "Literature Review: Advantages and Disadvantages of Black Box and White Box Testing Methods," *Jurnal Techno Nusa Mandiri*, vol. 21, no. 2, pp. 151–162, 2024, doi: 10.33480/techno.v21i2.5776.