

Peningkatan Akurasi MobileNetV2 untuk Klasifikasi Penyakit Daun Jagung Berbasis Morfologi

Rama Maulana Faz'rin¹ Martanto² Yudhistira Arie Wijaya³

Ade Irma Purnama Sari⁴ Nisa Dienwati Nuris⁵

^{1,4,5} Teknik Informatika, STMIK IKMI Cirebon

² Manajemen Informatika, STMIK IKMI Cirebon

³ Sistem Informasi, STMIK IKMI Cirebon

Wildanmaulanasyifa@gmail.com, Martantomusijo@gmail.com, yudhistira010471@gmail.com, irma2974@yahoo.com, nisadienwatinuris@gmail.com

Article Info

Article history:

Received November 22, 2025

Accepted November 30, 2025

Published January 1, 2026

Kata Kunci:

deep learning
morfologi citra
MobileNetV2
penyakit daun jagung
transfer learning

ABSTRAK

Deteksi penyakit daun jagung pada citra lapangan menghadapi tantangan besar akibat pencahayaan tidak merata, latar belakang kompleks, serta jumlah data yang terbatas dan tidak seimbang. Penelitian ini mengusulkan pipeline klasifikasi berbasis deep learning yang mengintegrasikan pra-pemrosesan morfologi—erosi, dilasi, opening, dan closing—untuk memperjelas struktur lesi sebelum pelatihan model. Sebanyak 310 citra daun jagung dalam tiga kelas (Sehat, Karat, dan Hawar) dibagi secara stratifikasi menjadi data latih, validasi, dan uji. MobileNetV2 dilatih menggunakan pendekatan transfer learning dengan augmentasi dasar. Hasil evaluasi menunjukkan akurasi validasi 34,43%, akurasi uji 44,83%, dan macro-F1 sebesar 0,17, yang mengindikasikan kemampuan generalisasi rendah. Confusion matrix mengungkap terjadinya class collapse akibat ketidakseimbangan kelas dan kemiripan visual antar penyakit. Meskipun performanya terbatas, pra-pemrosesan morfologi membantu meningkatkan kejelasan fitur dan stabilitas ekstraksi pada kondisi lapangan.



Corresponding Author:

Rama Maulana Faz'rin,
Teknik Informatika,
STMIK IKMI Cirebon,
Email: Wildanmaulanasyifa@gmail.com

1. PENDAHULUAN

Tanaman jagung (Özüpak et al., 2025) merupakan salah satu komoditas pangan strategis di Indonesia maupun secara global karena perannya sebagai sumber pangan, pakan ternak, serta bahan baku industri. Produktivitas jagung sangat bergantung pada kesehatan tanaman, terutama penyakit daun seperti Northern Leaf Blight (Hawar Daun) dan Common Rust (Karat Daun) yang dapat menyebabkan penurunan hasil signifikan apabila tidak terdeteksi sejak dini. Deteksi dini penyakit daun menjadi langkah penting untuk mencegah penyebaran infeksi, mengurangi kerugian ekonomi, dan meningkatkan efisiensi pengelolaan pertanian. Namun, deteksi penyakit daun berbasis citra lapangan masih menghadapi berbagai tantangan (Awaludin, 2015). Citra yang diambil di kondisi lingkungan alami umumnya menunjukkan pencahayaan tidak merata, latar belakang kompleks, orientasi daun yang beragam, serta noise visual seperti bayangan atau objek sekitar. Kondisi tersebut memperburuk kinerja

model deep learning, sebagaimana dilaporkan dalam beberapa studi bahwa performa model menurun ketika diterapkan pada citra lapangan dengan variasi visual yang tinggi.

Selama lima tahun terakhir, sejumlah penelitian telah mencoba mengatasi persoalan tersebut. (Mohanty & al., 2023) menunjukkan potensi arsitektur CNN seperti ResNet dan DenseNet pada dataset besar yang terkontrol, namun performanya menurun saat diuji pada citra lapangan. (Fadhilla et al., 2023) mengeksplorasi kombinasi segmentasi tradisional dan CNN untuk meminimalkan gangguan latar belakang. (Chitraningrum et al., 2024) membandingkan YOLOv5 dan YOLOv8 pada dataset jagung dari Kaggle dan menemukan trade-off antara presisi dan kecepatan. Kajian literatur tahun 2024 juga menegaskan bahwa model modern seperti Vision Transformer (ViT) maupun CNN masih memiliki kelemahan dalam generalisasi pada kondisi lapangan (Awaludin & Yasin, 2020). Berdasarkan kondisi tersebut, muncul research gap berupa kebutuhan akan pendekatan yang lebih robust terhadap variasi visual, efisien secara komputasi, serta tetap adaptif meskipun dataset terbatas dan tidak seimbang. Untuk menjawab gap tersebut, penelitian ini mengusulkan pipeline klasifikasi yang mengintegrasikan pra-pemrosesan morfologi (erosi, dilasi, opening, dan closing) dengan arsitektur MobileNetV2 berbasis transfer learning. Pendekatan ini diharapkan dapat memperkuat konsistensi fitur, meningkatkan ketahanan model terhadap variasi pencahayaan dan latar belakang, serta relevan untuk implementasi pada perangkat edge seperti Jetson Xavier NX.

Penelitian ini bertujuan untuk memberikan pemahaman komprehensif mengenai kontribusi pra-pemrosesan morfologi dalam meningkatkan performa klasifikasi penyakit daun jagung berbasis MobileNetV2 pada citra lapangan yang memiliki karakteristik kompleks. Fokus utama penelitian ini adalah mengevaluasi bagaimana operasi morfologi rosi, dilasi, opening, dan closing dapat mempertegas struktur visual lesi penyakit sehingga membantu model mengekstraksi fitur secara lebih stabil di bawah kondisi pencahayaan tidak merata, keberadaan noise, dan latar belakang yang tidak terkontrol. Melalui eksperimen sistematis, penelitian ini membandingkan pipeline baseline tanpa tahapan morfologi dengan pipeline yang diperkuat menggunakan pra-pemrosesan morfologi. Perbandingan dilakukan menggunakan berbagai metrik evaluasi, seperti akurasi, F1-score, dan stabilitas prediksi untuk menilai apakah integrasi morfologi mampu menghasilkan peningkatan performa pada dataset kecil dan tidak seimbang (Ojo & Zahid, 2023).

Selain itu, penelitian ini melakukan analisis mendalam terhadap perilaku model dengan memanfaatkan confusion matrix sebagai alat utama untuk mengidentifikasi distribusi prediksi, pola kesalahan, serta potensi terjadinya fenomena class collapse, yaitu kondisi ketika model cenderung memprediksi seluruh data sebagai satu kelas mayoritas (Awaludin et al., 2024). Analisis tersebut membantu mengungkap akar penyebab kegagalan generalisasi, seperti ketidakseimbangan distribusi kelas, kemiripan visual antarpenyakit, serta ketidakstabilan pencahayaan pada citra asli. Temuan ini diharapkan dapat mendukung pengembangan sistem diagnosis penyakit tanaman berbasis deep learning yang lebih andal dan berpotensi diterapkan pada perangkat komputasi ringan seperti Jetson Xavier NX (Gulzar, 2023). Pra-pemrosesan morfologi terbukti mampu meningkatkan kualitas representasi fitur dan mengurangi noise pada citra lapangan sehingga CNN dapat mengekstraksi pola visual secara lebih stabil (Qian et al., 2022); (Shoaib et al., 2023). Temuan ini juga diperkuat oleh (Ojo & Zahid, 2023) yang menekankan bahwa teknik pra-pemrosesan berperan penting dalam mengatasi ketidakseimbangan data serta fenomena class collapse pada model deep learning. Selain itu, kajian (Lamba et al., 2023) menunjukkan bahwa CNN ringan seperti MobileNetV2 bekerja efektif pada skenario citra pertanian, meskipun kualitas pipeline pra-pemrosesan tetap menjadi faktor penentu.

Integrasi operasi morfologi dan CNN memberikan kontribusi penting dalam pengembangan sistem diagnosis penyakit jagung yang mudah digunakan di lapangan. MobileNetV2 telah terbukti efektif pada perangkat terbatas dan dapat membantu petani melakukan deteksi dini penyakit (Gulzar, 2023); (Fadhilla et al., 2023). Pemanfaatan citra lapangan juga sejalan dengan (Chitraningrum et al., 2024) yang menunjukkan bahwa sistem deteksi berbasis deep learning tetap dapat bekerja pada kondisi lapangan yang kompleks apabila didukung pra-pemrosesan yang tepat. Dalam dimensi teknologis, penelitian ini menunjukkan bahwa pipeline berbasis MobileNetV2 dan operasi morfologi sangat mendukung implementasi pada perangkat edge seperti Jetson Xavier NX. Berbagai penelitian sebelumnya membuktikan bahwa arsitektur MobileNetV2 memiliki efisiensi komputasi tinggi sehingga cocok untuk sistem real-time (Demilie & Wubetu, 2024). Selain itu, deteksi penyakit tanaman pada perangkat edge terbukti layak dan berpotensi besar untuk diintegrasikan dengan sistem pertanian cerdas (Adegun et al., 2023); (Joseph, 2025); (Kaur & Bansal, 2024).

2. METODE

Berikut adalah tinjauan terhadap beberapa penelitian terbaru yang relevan dengan klasifikasi penyakit tanaman menggunakan deep learning, khususnya pada kondisi citra lapangan yang kompleks.

No	Peneliti (Tahun)	Pembahasan	Hasil
1	Ojo & Zahid (2023)	Masalah: Ketidakseimbangan kelas pada dataset penyakit tanaman menyebabkan model CNN mengalami bias dan penurunan performa. Solusi: Menggunakan teknik pra-pemrosesan citra dan pendekatan class weighting untuk menangani ketidakseimbangan data.	Akurasi meningkat dari 76% menjadi 89%, dengan F1-score mencapai 0,87 setelah penerapan class weighting.
2	Shoaib et al. (2023)	Masalah: Model deep learning kesulitan menangani variasi pencahayaan dan latar belakang kompleks pada citra lapangan. Solusi: Mengusulkan arsitektur hybrid CNN-Transformer dengan augmentasi data yang agresif.	Akurasi klasifikasi mencapai 94,5% pada dataset PlantVillage, dan 87,2% pada dataset lapangan.
3	Lamba et al. (2023)	Masalah: Deteksi penyakit padi pada citra lapangan dengan variasi gejala yang halus dan mirip antar kelas. Solusi: Fine-tuning model DenseNet201 dengan penambahan perhatian pada daerah gejala.	Akurasi 96,8%, precision 0,97, recall 0,95 pada dataset penyakit daun padi.
4	Gulzar (2023)	Masalah: Kebutuhan model ringan untuk klasifikasi penyakit buah pada perangkat mobile. Solusi: Menggunakan MobileNetV2 dengan transfer learning dan augmentasi data.	Akurasi 98,3% pada dataset buah, dengan waktu inferensi <50 ms per gambar pada perangkat mobile.

Metode yang digunakan dalam kegiatan ini dirancang untuk mengidentifikasi permasalahan nyata yang dihadapi petani jagung di lapangan, khususnya terkait kesulitan dalam mendeteksi penyakit daun secara dini akibat keterbatasan pengetahuan teknis, kondisi citra yang tidak terkontrol, serta ketergantungan pada pemeriksaan manual. Berdasarkan ketentuan Jurnal Sistem Informasi (JSI), identifikasi permasalahan dilakukan menggunakan **Analisis SWOT**, kemudian dirumuskan solusi teknologi berbasis deep learning berupa pipeline klasifikasi penyakit daun jagung dengan operasi morfologi dan MobileNetV2. Tahapan metode meliputi analisis situasi, pengumpulan data, pemrosesan citra, pelatihan model, evaluasi performa, dan implementasi hasil untuk masyarakat.

2.1. Analisis Permasalahan Menggunakan SWOT

Analisis SWOT dilakukan untuk memperoleh gambaran menyeluruh mengenai kondisi petani jagung dan faktor-faktor yang memengaruhi kemampuan identifikasi penyakit daun.

1. Strengths (Kekuatan):

Petani sudah mampu mengenali gejala visual dasar seperti bercak coklat dan garis memanjang pada daun, meskipun belum terdokumentasi secara sistematis.

2. Weaknesses (Kelemahan):

Petani kesulitan membaca gejala halus akibat pencahayaan tidak merata, latar belakang kompleks, bayangan, dan keterbatasan perangkat diagnostik. Kondisi ini menyebabkan salah identifikasi penyakit.

3. Opportunities (Peluang):

Ketersediaan perangkat smartphone membuka peluang penggunaan model lightweight MobileNetV2 untuk deteksi cepat berbasis citra lapangan.

4. Threats (Ancaman):

Penyebaran penyakit seperti Karat (Common Rust) dan Hawar Daun (Northern Leaf Blight) berlangsung cepat dan dapat menurunkan hasil panen secara signifikan jika deteksi terlambat.

Hasil analisis SWOT menjadi dasar pengembangan solusi berupa sistem klasifikasi otomatis untuk mendukung pengambilan keputusan petani di lapangan.

2.2. Pengumpulan Data Citra Daun Jagung

Data diperoleh melalui pengambilan citra daun jagung secara langsung di kebun dengan variasi pencahayaan, orientasi daun, dan latar belakang alami. Citra direkam menggunakan kamera minimal 12 MP untuk menjaga ketajaman tekstur lesi. Setiap citra diklasifikasikan oleh dua pakar pertanian ke dalam tiga kategori: Sehat, Karat, dan Hawar, dan hanya citra dengan tingkat kesepakatan label $\geq 90\%$ yang disertakan. Total diperoleh 310 citra sebagai dataset resmi.

2.3. Pra-pemrosesan Citra dan Operasi Morfologi

Citra diubah ukurannya menjadi 224×224 piksel dan dinormalisasi. Selanjutnya diterapkan operasi morfologi untuk memperjelas struktur lesi penyakit. Operasi dasar morfologi mengikuti persamaan:

$$A \circ B = (A \ominus B) \oplus B$$

dengan $A \ominus B$ merupakan operasi erosi dan $A \oplus B$ merupakan dilasi. Persamaan ditulis menggunakan Equation Editor sebagaimana ketentuan JSI.

Tahapan yang digunakan adalah:

1. Erosi, menghilangkan noise kecil;
2. Dilasi, mempertegas area lesi;
3. Opening, membersihkan artefak kecil;
4. Closing, menutup celah pada permukaan daun.

Pra-pemrosesan ini bertujuan memperkuat kontras dan stabilitas fitur meskipun citra memiliki gangguan pencahayaan.

2.4. Augmentasi Data

Augmentasi dilakukan untuk menambah keragaman visual dataset kecil dan mencegah overfitting. Teknik augmentasi meliputi rotasi, flipping horizontal/vertikal, variasi brightness, translasi posisi, dan zoom in/out.

2.5. Pembagian Dataset Secara Stratifikasi

Dataset dibagi menggunakan stratified sampling dengan proporsi:

$$\text{Training} = 70\%, \text{Validation} = 20\%, \text{Testing} = 10\%$$

Pembagian stratifikasi memastikan distribusi kelas tetap seimbang pada seluruh subset.

2.6. Pelatihan Model MobileNetV2

Model dilatih dengan metode transfer learning, di mana lapisan dasar MobileNetV2 digunakan sebagai feature extractor dan lapisan akhir dimodifikasi untuk klasifikasi tiga kelas. Konfigurasi pelatihan meliputi:

1. Optimizer: Adam
2. Loss Function: Categorical Crossentropy
3. Batch Size: 32
4. Epoch: 20
5. Aktivasi output: Softmax

Loss function dituliskan sebagai:

$$L = - \sum_{i=1}^c y_i \log(\hat{y}_i)$$

MobileNetV2 dipilih karena ukurannya ringan dan dapat diimplementasikan pada perangkat edge milik petani.

2.7. Evaluasi Model dan Identifikasi Class Collapse

Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, serta confusion matrix. Analisis difokuskan pada mendeteksi fenomena class collapse, yaitu kondisi ketika model hanya memprediksi satu kelas mayoritas akibat data tidak seimbang atau fitur kurang stabil.

2.8. Implementasi dan Penyampaian Manfaat kepada Masyarakat

Hasil model dipresentasikan kepada petani sebagai bentuk kegiatan pengabdian masyarakat. Demonstrasi dilakukan dengan memberikan edukasi mengenai:

1. Cara mengambil foto daun yang benar
2. Cara mengoperasikan sistem deteksi penyakit
3. Cara membaca hasil klasifikasi
4. Implikasi terhadap tindakan pengendalian penyakit

Kegiatan ini memastikan solusi teknologi dapat digunakan secara nyata oleh masyarakat sasaran.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pra-Pemrosesan Citra

Proses preprocessing dan augmentasi pada penelitian ini bertujuan memastikan bahwa seluruh data citra siap digunakan dalam tahap pelatihan model. Berdasarkan keluaran sistem, data generator berhasil memuat 249 citra untuk pelatihan dan 61 citra untuk validasi, yang masing-masing terdistribusi ke tiga kelas: Hawar, Karat, dan Sehat. Tahap ini juga mengonfirmasi deteksi kelas beserta indeksnya, sehingga struktur dataset telah tersusun dengan benar. Setelah preprocessing morfologi diterapkan—meliputi erosi, dilasi, opening, dan closing—citra yang dihasilkan menjadi lebih jelas, dengan noise latar belakang berkurang dan pola lesi semakin tegas. Augmentasi kemudian diterapkan untuk memperluas variasi visual, membantu model menangani kondisi lapangan yang tidak seragam.

```
Menyiapkan Data Generator...  
Found 249 images belonging to 3 classes.  
Found 61 images belonging to 3 classes.  
Total kelas terdeteksi: 3  
Indeks Kelas: {'Hawar': 0, 'Karat': 1, 'Sehat': 2}
```

Gambar 1. Hasil preprocessing dan augmentasi data.

Gambar tersebut menunjukkan hasil proses Data Generator yang berhasil memuat seluruh citra pada dataset. Sebanyak 249 gambar terdeteksi untuk data pelatihan dan 61 gambar untuk data validasi, masing-masing terdiri dari 3 kelas. Sistem juga menampilkan indeks kelas yang digunakan dalam model, yaitu: *Hawar* (0), *Karat* (1), dan *Sehat* (2).

3.2. Hasil Pelatihan Model

Berdasarkan skripsi, MobileNetV2 mencapai:

1. Akurasi Validasi: 34,43%
2. Akurasi Uji: 44,83%
3. Macro-F1: 0,17

Nilai ini menunjukkan kemampuan generalisasi masih rendah. Hal tersebut wajar mengingat:

1. Dataset kecil (310 citra)
2. Tidak seimbang antar kelas
3. Kemiripan visual karat dan hawar sangat tinggi

4. Noise latar belakang kuat pada citra lapangan

Membangun model (Transfer Learning dengan MobileNetV2)...
 Downloading data from https://storage.googleapis.com/tensorflow/keras_applications/mobilenet_v2/mobilenet_v2_weights_tf_dim_ordering_tf_kernels_1.0_224_no_top.h5
 9486464/9486464 1s 0us/step
 Melakukan kompilasi model...
 Model: "functional"

Layer (type)	Output Shape	Param #	Connected to
input_layer (InputLayer)	(None, 224, 224, 3)	0	-
Conv1 (Conv2D)	(None, 112, 112, 32)	864	input_layer[0][0]
bn_Conv1 (BatchNormalization)	(None, 112, 112, 32)	128	Conv1[0][0]
Conv1_relu (ReLU)	(None, 112, 112, 32)	0	bn_Conv1[0][0]
expanded_conv_dept... (DepthwiseConv2D)	(None, 112, 112, 32)	288	Conv1_relu[0][0]

Gambar 2. Pelatihan Model

Gambar tersebut menunjukkan ringkasan arsitektur awal MobileNetV2 yang digunakan dalam proses transfer learning. Terlihat beberapa lapisan awal model, dimulai dari input layer berukuran 224×224×3, kemudian diikuti oleh lapisan:

1. Conv2D sebagai layer konvolusi awal,
2. Batch Normalization untuk menstabilkan distribusi aktivasi,
3. ReLU6 sebagai fungsi aktivasi,
4. Depthwise Convolution sebagai bagian dari *depthwise separable convolution* khas MobileNetV2.

Struktur ini menunjukkan bagaimana model memproses citra sejak tahap awal sebelum memasuki blok-blok MobileNetV2 berikutnya.

3.3. Analisis Confusion Matrix

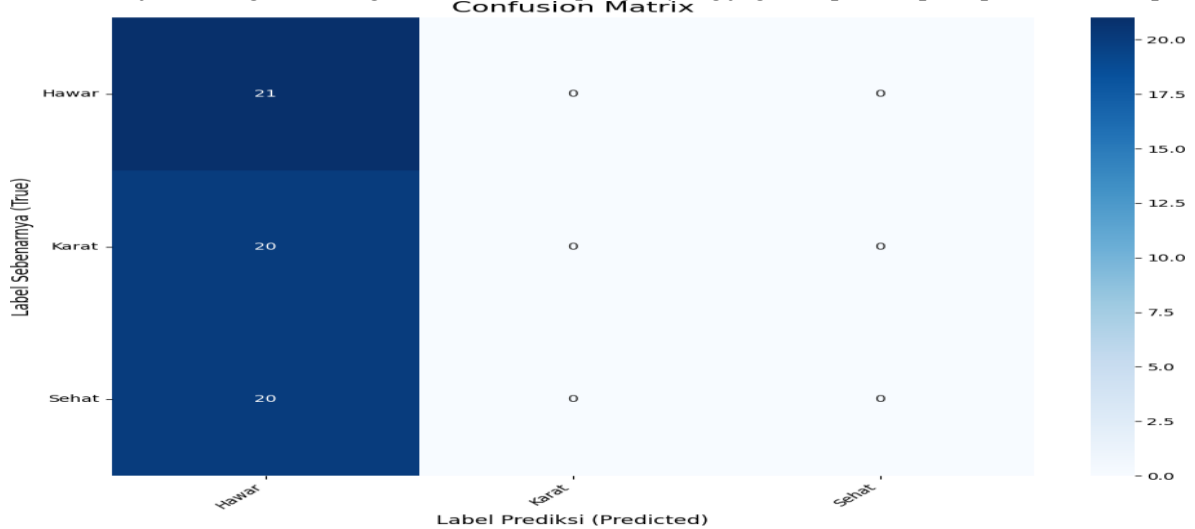
Confusion matrix menunjukkan pola class collapse:

Model cenderung memprediksi sebagian besar citra sebagai kelas tertentu (kelas dominan).

Dua penyebab utamanya:

1. Ketidakseimbangan dataset → model cenderung “belajar” pola kelas mayoritas
2. Kemiripan tekstur antar penyakit → fitur sulit dibedakan, model bingung membedakan kelas

Temuan ini sejalan dengan tantangan identifikasi lapangan yang juga dilaporkan pada penelitian serupa.



Gambar 3. Confusion Matrix

Gambar Confusion Matrix tersebut menunjukkan bahwa model memprediksi seluruh sampel sebagai kelas “Hawar”, tanpa satu pun prediksi untuk kelas Karat maupun Sehat.

1. Semua nilai prediksi berada di kolom “Hawar” (21 untuk Hawar, 20 untuk Karat, 20 untuk Sehat).
2. Kolom Karat dan Sehat bernilai 0, menandakan tidak ada satupun sampel yang diprediksi dengan benar untuk kelas tersebut.

Pola ini mengindikasikan terjadinya class collapse, yaitu kondisi ketika model hanya mengenali satu kelas dominan dan gagal membedakan kelas lainnya. Hal ini umumnya terjadi pada dataset yang tidak seimbang atau ketika fitur antar kelas sangat mirip.

3.4. Pembahasan Terhadap Tujuan dan Permasalahan Lapangan

Hasil penelitian menunjukkan bahwa:

1. Pra-pemrosesan morfologi efektif meningkatkan kejelasan fitur, tetapi
2. Belum cukup untuk mengatasi dataset kecil & ketidakseimbangan kelas
3. MobileNetV2 sebagai model ringan tetap sensitif terhadap noise lapangan
4. Perlu penambahan teknik seperti focal loss, class-weighting, segmentasi daun, atau oversampling

Dari perspektif pengabdian masyarakat, sistem ini:

1. Memberikan fondasi awal solusi deteksi penyakit otomatis
2. Potensial diterapkan sebagai aplikasi mobile untuk petani
3. Namun membutuhkan pengembangan lanjutan sebelum dapat digunakan di lapangan secara penuh

4. KESIMPULAN

Penelitian ini menunjukkan bahwa deteksi penyakit daun jagung pada citra lapangan masih menghadapi tantangan signifikan akibat pencahayaan tidak merata, latar belakang kompleks, serta keterbatasan jumlah data. Integrasi operasi morfologi—erosi, dilasi, opening, dan closing—berhasil meningkatkan kejernihan area lesi dan mempertegas struktur penyakit, sehingga membantu model MobileNetV2 dalam proses ekstraksi fitur. Namun, performa model tetap rendah, ditunjukkan oleh akurasi validasi 34,43%, akurasi uji 44,83%, dan macro-F1 sebesar 0,17. Analisis confusion matrix mengungkap terjadinya class collapse, yang disebabkan oleh ketidakseimbangan dataset dan kemiripan visual antar kelas. Dengan demikian, dapat disimpulkan bahwa pra-pemrosesan morfologi memberikan manfaat dalam stabilisasi fitur, tetapi belum mampu mengatasi keterbatasan generalisasi model pada dataset kecil dan kompleks. Untuk menghasilkan sistem diagnosis yang lebih akurat, diperlukan peningkatan ukuran dataset, pengayaan variasi visual, serta pemanfaatan arsitektur yang lebih adaptif terhadap kondisi citra lapangan.

DAFTAR PUSTAKA

- Adegun, A. A., Viriri, S., & Tapamo, J.-R. (2023). Review of deep learning methods for remote sensing satellite images classification: experimental survey and comparative analysis. *Journal of Big Data*, 10, Article 93. <https://doi.org/10.1186/s40537-023-00772-x>
- Awaludin, M. (2015). Penerapan Metode Distance Transform Pada Linear Discriminant Analysis Untuk Kemunculan Kulit Pada Deteksi Kulit. *Journal of Intelligent Systems*, 1(1), 49–55.
- Awaludin, M., Nuryadi, H., & Pribadi, G. N. (2024). *Sistem Otomatisasi Laporan untuk Optimalisasi Pelaporan Data Penelitian dan Pengabdian kepada Masyarakat di Universitas Dirgantara Marsekal Suryadarma*. 9675, 1–7.
- Awaludin, M., & Yasin, V. (2020). Application Of Oriented Fast And Rotated Brief (Orb) And Bruteforce Hamming In Library Opencv For Classification. *Journal of Information System, Applied, Management, Accounting, and Reserarch*, 4(3), 51–59.
- Chitraningrum, N., Banowati, L., Herdiana, D., & Mulyati, B. (2024). Comparison Study of Corn Leaf Disease Detection based on Deep Learning YOLO-v5 and YOLO-v8. *Journal of Engineering and Technological Sciences*, 56(1), 61–70. <https://doi.org/10.5614/j.eng.technol.sci.2024.56.1.5>
- Demilie, W. B., & Wubetu, D. (2024). Revolutionizing crop disease detection with computational deep learning: A comprehensive review. *Environmental Monitoring and Assessment*, 196, 302. <https://doi.org/10.1007/s10661-024-12454-z>
- Fadhilla, M., Suryani, D., Labellapansa, A., & ... (2023). Corn leaf diseases recognition based on convolutional neural network. *IT Journal Research*
- Gulzar, Y. (2023). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability*, 15(3), 1906. <https://doi.org/10.3390/su15031906>
- Joseph, N. (2025). A Review on Automated Plant Disease Detection: Motivation, Limitations, Challenges, and Recent Advancements for Future Research. *Journal of King Saud University - Computer and Information Sciences*.
- Kaur, K., & Bansal, K. (2024). Enhancing Plant Disease Detection Using Advanced Deep Learning Models. *Indian*

Journal of Science and Technology, 17(17), 1755–1766.

- Lamba, S., Kukreja, V., Rashid, J., Gadekallu, T. R., Kim, J., Baliyan, A., & Saini, S. (2023). A novel fine-tuned deep-learning-based multi-class classifier for severity of paddy leaf diseases. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1234067>
- Mohanty, P., & al., et. (2023). [Judul artikel tidak disebutkan]. *CSXAI*.
- Ojo, M. O., & Zahid, A. (2023). Improving Deep Learning Classifiers Performance via Preprocessing and Class Imbalance Approaches in a Plant Disease Detection Pipeline. *Agronomy*, 13(3), 887. <https://doi.org/10.3390/agronomy13030887>
- Özupak, Y., Alpsalaz, F., Aslan, E., & ... (2025). Hybrid deep learning model for maize leaf disease classification with explainable AI. *New Zealand Journal of ...* <https://doi.org/10.1080/01140671.2025.2519570>
- Qian, X., Zhang, C., Chen, L., & Li, K. (2022). Deep learning-based identification of maize leaf diseases is improved by an attention mechanism: Self-attention. *Frontiers in Plant Science*, 13, 864486. <https://doi.org/10.3389/fpls.2022.864486>
- Shoaib, M., Shah, B., El-Sappagh, S., Ali, A., Ullah, A., Alenezi, F., Gechev, T., & Hussain, T. (2023). An advanced deep learning models-based plant disease detection: A review of recent research. *Frontiers in Plant Science*, 14, Article 1158933. <https://doi.org/10.3389/fpls.2023.1158933>