

Klasifikasi Penyakit Tanaman Nanas di Kota Prabumulih Menggunakan Model Transfer Learning Berbasis Mobilenetv3-Large

Classification of Pineapple Plant Diseases in Prabumulih City Using a Transfer Learning Model Based on MobileNetV3-Large

Jenny Rahma Hidayah^{*1}, Jemakmun²

^{1,2}Teknik Informatika, Universitas Bina Darma, Palembang 30264

E-mail : 211420044@student.binadarma.ac.id^{*1}, jemakmun@binadarma.ac.id²

**Corresponding author*

Received 13 August 2025; Revised 17 September 2025; Accepted 2 October 2025

Abstrak -Tanaman nanas merupakan salah satu komoditas pertanian unggulan di Kota Prabumulih, Sumatera Selatan. Namun, produktivitasnya menurun akibat penyakit seperti fruit rot, root rot, dan mealybug wilt yang sulit dikenali dengan cepat oleh petani. Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit tanaman nanas berbasis citra digital dengan pendekatan transfer learning menggunakan arsitektur MobileNetV3-Large. Dataset terdiri dari citra primer hasil dokumentasi lapangan dan citra sekunder dari Roboflow, yang dikategorikan dalam empat kelas: sehat, fruit rot, root rot, dan mealybug wilt. Proses penelitian mencakup pra-pemrosesan data (resize, augmentasi, normalisasi), pelatihan model dalam dua tahap (ekstraksi fitur dan fine-tuning), serta evaluasi menggunakan akurasi, presisi, recall, dan F1-score. Hasil pengujian menunjukkan akurasi validasi sebesar 91% dan F1-score sebesar 90%, yang mencerminkan performa klasifikasi yang baik dan stabil. Model juga diimplementasikan ke dalam aplikasi berbasis Gradio untuk pengujian interaktif. Hasil penelitian ini menunjukkan bahwa pendekatan transfer learning dengan arsitektur MobileNetV3-Large efektif untuk klasifikasi penyakit tanaman nanas dan berpotensi diintegrasikan ke dalam sistem deteksi penyakit pertanian secara praktis.

Kata kunci: tanaman nanas, klasifikasi citra, MobileNetV3, transfer learning, deep learning

Abstract - Pineapple is one of the major agricultural commodities in Prabumulih City, South Sumatra. However, its productivity is declining due to diseases such as fruit rot, root rot, and mealybug wilt, which are often difficult to detect early by farmers. This study aims to develop a pineapple disease classification system based on digital images using transfer learning with the MobileNetV3-Large architecture. The dataset used in this research consists of primary images collected from field documentation and secondary images obtained from the Roboflow platform. It includes five classes: healthy, fruit rot, root rot, mealybug wilt, and an additional unknown class representing irrelevant or non-pineapple images. The research process includes image preprocessing (resizing, augmentation, normalization), two-stage model training (feature extraction and fine-tuning), and evaluation using metrics such as accuracy, precision, recall, and F1-score. The final evaluation shows a validation accuracy of 91% and an F1-score of 90%, indicating reliable and consistent classification performance. The trained model is also deployed in a Gradio-based application to facilitate interactive testing. These results demonstrate that the proposed approach is effective and has practical potential in supporting early disease detection in pineapple farming systems.

Keywords: pineapple plant, image classification, MobileNetV3, transfer learning, deep learning

1. PENDAHULUAN

Pertanian merupakan sektor strategis yang memiliki peranan penting dalam pembangunan nasional, baik sebagai penyedia bahan pangan maupun sebagai penyumbang utama Produk Domestik Regional Bruto (PDRB) di banyak daerah. Di Provinsi Sumatera Selatan, sektor pertanian menyumbang lebih dari 19% terhadap PDRB, menunjukkan perannya yang vital dalam mendukung ketahanan pangan dan perekonomian daerah. Salah satu komoditas hortikultura unggulan adalah nanas (*Ananas comosus*), yang di Kota Prabumulih menjadi ikon pertanian sekaligus sumber penghasilan utama bagi sebagian besar petani. Data Dinas Pertanian Kota Prabumulih mencatat produksi nanas mencapai lebih dari 4,7 juta kuintal pada tahun 2023 [1].

Namun demikian, produktivitas nanas sangat rentan terhadap serangan penyakit tanaman, di antaranya fruit rot, root rot, dan mealybug wilt. Penyakit-penyakit tersebut dapat menurunkan kualitas buah secara signifikan bahkan menyebabkan gagal panen apabila tidak segera ditangani [2]. Identifikasi penyakit oleh petani masih dilakukan secara manual berdasarkan pengamatan visual, yang bersifat subjektif, bergantung pada pengalaman, serta tidak efisien untuk diterapkan dalam skala luas. Oleh karena itu, dibutuhkan sistem otomatis berbasis kecerdasan buatan untuk mendukung diagnosis penyakit tanaman nanas secara cepat dan akurat.

Perkembangan teknologi kecerdasan buatan (Artificial Intelligence/AI), khususnya deep learning, telah memberikan solusi inovatif di bidang pertanian presisi [3]. Convolutional Neural Network (CNN) terbukti efektif dalam mengekstraksi fitur visual kompleks dari citra digital, sehingga banyak dimanfaatkan untuk klasifikasi penyakit tanaman [4]. Rahman dan Pratiwi [5] berhasil menggunakan arsitektur VGG-16 untuk klasifikasi penyakit daun tomat dan anggur dengan akurasi di atas 90%. Shoaib et al. [6] melakukan tinjauan komprehensif terhadap berbagai metode deep learning dan menekankan peran transfer learning dalam mengatasi keterbatasan data berukuran kecil.

Sejumlah penelitian juga telah mengeksplorasi berbagai arsitektur CNN. Linli et al. [7] membandingkan arsitektur CNN, termasuk ResNet-50 yang ditingkatkan (dengan mekanisme attention dan DropBlock regularization), dalam klasifikasi penyakit tomat, dan menemukan bahwa ResNet-50 memberikan hasil terbaik dengan akurasi pengenalan sekitar 98,10%. Srinivasan et al. [8] mengembangkan DBA-ViNet berbasis explainable AI untuk deteksi penyakit buah, yang tidak hanya melakukan klasifikasi, tetapi juga menyajikan interpretasi visual. Herimanto et al. [9] menerapkan MobileNetV3 dalam klasifikasi citra medis dan menunjukkan bahwa arsitektur ini memiliki efisiensi tinggi serta cocok untuk implementasi pada perangkat terbatas.

Tahapan pra-pemrosesan data juga terbukti penting dalam meningkatkan kinerja model. Xu et al. [10] menjelaskan bahwa augmentasi citra mampu meningkatkan generalisasi CNN dengan menciptakan variasi data baru. Saddami et al. [11] memanfaatkan EfficientNet-B0 dalam klasifikasi penyakit daun padi dan menunjukkan hasil akurasi yang lebih tinggi dibandingkan CNN konvensional. Fuentes et al. [12] mengembangkan sistem deteksi multi-penyakit tomat menggunakan Faster R-CNN, yang menunjukkan potensi metode deteksi objek dalam menangani kasus kompleks. Ferentinos [13] melatih CNN pada dataset PlantVillage dan mencapai akurasi hingga 99% untuk 58 penyakit tanaman, namun penelitian tersebut terbatas pada kondisi laboratorium yang terkontrol.

Transfer learning semakin banyak digunakan pada penelitian agrikultur karena dapat memanfaatkan bobot prelatih dari dataset besar seperti ImageNet. Khamparia dan Singh [14] menegaskan bahwa arsitektur ringan seperti MobileNet lebih sesuai untuk aplikasi pada perangkat bergerak. Kumar et al. [15] berhasil mengintegrasikan CNN ke dalam aplikasi mobile untuk deteksi penyakit jagung secara real-time, menunjukkan potensi implementasi praktis bagi petani.


Dari berbagai penelitian terdahulu tersebut, dapat diidentifikasi beberapa kesenjangan penelitian (research gap). Pertama, sebagian besar penelitian masih menggunakan dataset publik seperti PlantVillage, yang kurang merepresentasikan kondisi agronomis lokal dengan variasi

cahaya, latar, dan morfologi tanaman. Kedua, penelitian tentang penyakit nanas masih sangat terbatas, sedangkan komoditas lain seperti tomat, padi, dan jagung telah lebih banyak diteliti. Ketiga, sebagian besar studi hanya berfokus pada metrik akurasi tanpa memperhatikan metrik evaluasi lain yang lebih komprehensif seperti presisi, recall, dan F1-score. Keempat, masih jarang penelitian yang mengintegrasikan model klasifikasi penyakit tanaman ke dalam aplikasi interaktif yang dapat digunakan langsung oleh petani.

Untuk menjawab kesenjangan tersebut, penelitian ini merancang sistem klasifikasi penyakit tanaman nanas menggunakan transfer learning dengan arsitektur MobileNetV3-Large. Kebaruan penelitian ini meliputi: (1) pemanfaatan dataset gabungan dari citra lapangan (primer) dan dataset publik (sekunder) yang merepresentasikan kondisi nyata di Prabumulih; (2) penambahan kelas unknown agar model lebih robust terhadap citra non-nanas; (3) strategi pelatihan dua tahap (feature extraction dan fine-tuning) untuk meningkatkan akurasi; serta (4) implementasi model dalam aplikasi berbasis Gradio untuk diagnosis interaktif. Dengan pendekatan ini, diharapkan dapat dihasilkan sistem yang lebih adaptif, akurat, dan aplikatif dalam membantu petani nanas melakukan deteksi dini penyakit.

2. METODE PENELITIAN

Metodologi penelitian ini dirancang untuk menghasilkan sistem klasifikasi penyakit tanaman nanas berbasis citra digital dengan pendekatan transfer learning menggunakan arsitektur MobileNetV3-Large. Tahapan metodologi ditunjukkan pada Gambar 1, yang terdiri dari enam langkah utama: (1) akuisisi dataset, (2) pra-pemrosesan dan augmentasi, (3) desain model, (4) pelatihan model, (5) evaluasi performa, dan (6) implementasi aplikasi.



Gambar 1. Diagram Tahapan Proses

2.1 Akuisisi dan Persiapan Dataset

Dataset yang digunakan dalam penelitian ini terdiri atas 3.500 citra daun nanas yang terbagi menjadi lima kelas: Healthy, Fruit Rot, Root Rot, Mealybug Wilt, dan Unknown. Citra dikumpulkan dari dua sumber utama:

Data Primer: diperoleh melalui dokumentasi lapangan di Agrowisata Trans Bunut, Prabumulih, menggunakan kamera smartphone dengan resolusi tinggi.

Data Sekunder: diperoleh dari platform Roboflow, yang menyediakan dataset publik terkait penyakit nanas. Distribusi dataset ditunjukkan pada Tabel 1.

Tabel 1. Distribusi Dataset Penelitian

Kelas	Training	Validation	Testing	Total
Healthy	500	100	100	700
Fruit Rot	500	100	100	700
Root Rot	500	100	100	700
Mealybug Wilt	500	100	100	700
Unknown	500	100	100	700
Total	2.5	500	500	3.5

2.2 Pra-pemrosesan dan Augmentasi Citra

Tahap pra-pemrosesan dilakukan untuk memastikan data citra seragam dan sesuai kebutuhan model. Langkah-langkahnya meliputi:

- Resize: seluruh citra diubah ke ukuran 224×224 piksel agar sesuai dengan input MobileNetV3-Large.
- Normalisasi: nilai piksel diubah ke rentang $[-1, 1]$ menggunakan fungsi `preprocess_input` dari TensorFlow.
- Augmentasi Data: dilakukan secara real-time pada saat pelatihan untuk meningkatkan variasi data. Teknik augmentasi meliputi rotasi acak ($\pm 20^\circ$), horizontal flip, zoom ($\pm 10\%$), perubahan kecerahan, dan kontras. Augmentasi ini bertujuan mengurangi overfitting serta meningkatkan kemampuan generalisasi model pada kondisi lapangan yang bervariasi.

2.3 Transfer Learning

Transfer learning dipilih karena memungkinkan pemanfaatan bobot pralatih dari model besar yang sudah dilatih pada dataset umum seperti ImageNet. Pendekatan ini efektif dalam domain pertanian, yang biasanya memiliki keterbatasan jumlah data pelatihan. Dengan transfer learning, fitur-fitur dasar seperti tepi, tekstur, dan pola visual dari ImageNet dapat digunakan kembali untuk mendeteksi penyakit tanaman.

Strategi yang digunakan dalam penelitian ini adalah dua tahap:

- Feature Extraction $\rightarrow$ bobot lapisan backbone MobileNetV3-Large dibekukan, hanya lapisan klasifikasi baru yang dilatih.
- Fine-Tuning $\rightarrow$ sebagian lapisan backbone dibuka agar dapat dilatih dengan learning rate rendah ($1e-5$), sehingga model dapat menyesuaikan diri dengan karakteristik spesifik citra penyakit nanas.

2.4 Arsitektur MobileNetV3-Large

MobileNetV3 merupakan arsitektur CNN yang dikembangkan oleh Google dengan fokus pada efisiensi dan akurasi tinggi. Keunggulannya terletak pada:

- Depthwise Separable Convolution: mengurangi jumlah parameter dan perhitungan komputasi.
- Squeeze-and-Excitation (SE) Module: menyesuaikan bobot kanal fitur secara adaptif.
- Hard-Swish Activation: fungsi aktivasi yang lebih efisien dibanding ReLU, meningkatkan kinerja pada perangkat terbatas.

Pada penelitian ini, MobileNetV3-Large digunakan sebagai backbone dan dimodifikasi pada bagian akhir dengan penambahan lapisan:

- Global Average Pooling (GAP): mereduksi dimensi fitur menjadi vektor rata-rata.
- Dropout (0,5): mengurangi risiko overfitting.
- Dense Softmax (5 neuron): menghasilkan output sesuai jumlah kelas.

2.5 Strategi Pelatihan Model

Pelatihan dilakukan dalam dua tahap sesuai strategi transfer learning. Parameter pelatihan ditunjukkan pada Tabel 2.

Tabel 2. Parameter Pelatihan Model

Parameter	Nilai
Optimizer	Adam
Learning Rate	1e-4 (Feature Extraction), 1e-5 (Fine-Tuning)
Batch Size	32
Epoch	10 (Feature Extraction), 20 (Fine-Tuning)
Loss Function	Categorical Crossentropy
Metrics	Accuracy, Precision, Recall, F1-score

Selain itu, digunakan strategi regulasi berupa EarlyStopping, ReduceLROnPlateau, dan ModelCheckpoint untuk meningkatkan stabilitas pelatihan.

2.6 Evaluasi Model

Evaluasi performa dilakukan pada dataset pengujian (test set) menggunakan beberapa metrik klasifikasi multiclass:

- Accuracy: Proporsi prediksi benar dari seluruh data uji.
- Precision & Recall: Diukur per kelas untuk menilai ketepatan dan kelengkapan model.
- F1-Score: Rata-rata harmonik antara precision dan recall.
- Confusion Matrix: Untuk mengidentifikasi distribusi prediksi per kelas.

Selain itu, digunakan grafik training/validation accuracy dan loss untuk mengamati stabilitas pelatihan dan mendeteksi overfitting. Model terbaik disimpan dalam format .keras dan digunakan dalam proses deployment.

2.7 Implementasi Aplikasi

Model terbaik diintegrasikan ke aplikasi berbasis Gradio. Aplikasi ini memungkinkan pengguna mengunggah citra daun nanas, kemudian sistem menampilkan prediksi kelas, confidence score, serta informasi penyakit dan rekomendasi penanganannya. Penambahan kelas unknown berfungsi sebagai filter untuk meningkatkan keandalan sistem saat menerima input citra non-nanas.

3. HASIL DAN PEMBAHASAN

Bagian ini menjelaskan hasil pelatihan model klasifikasi, evaluasi kinerja model, serta implementasi ke dalam aplikasi interaktif. Analisis dilakukan terhadap efektivitas arsitektur MobileNetV3-Large dalam mendeteksi penyakit tanaman nanas berdasarkan citra daun.

3.1 Hasil Pelatihan Model

Model MobileNetV3-Large dilatih menggunakan pendekatan transfer learning dalam dua tahap, yaitu feature extraction dan fine-tuning. Hasil akhir menunjukkan bahwa model mencapai akurasi validasi sebesar 91,28% dengan nilai loss validasi 0,42 pada epoch ke-20. Performa ini konsisten dengan hasil pada dataset pengujian yang menghasilkan akurasi 90% dan F1-score 90%, sebagaimana ditunjukkan pada Tabel 3.


Tabel 3. Ringkasan Hasil Evaluasi Model

Dataset	Akurasi	Presisi	Recall	F1-Score
Validasi	91%	90%	90%	90%
Pengujian	90%	89%	88%	90%

Konsistensi antara hasil validasi dan pengujian menegaskan bahwa model mampu melakukan generalisasi dengan baik terhadap data baru.

3.2 Analisis Grafik Pelatihan

Performa pelatihan divisualisasikan pada Gambar 2, yang menunjukkan kurva akurasi dan loss selama proses training dan validasi.




Gambar 2. Grafik akurasi dan loss pada proses pelatihan

Berdasarkan grafik tersebut, akurasi model mengalami peningkatan stabil hingga mencapai 91% pada data validasi, sementara loss validasi menurun secara konsisten hingga 0,42. Kesesuaian tren antara training dan validation mengindikasikan bahwa model dilatih secara optimal dan mampu mempertahankan performa pada data yang tidak pernah dilihat sebelumnya.

3.3 Confusion Matrix

Distribusi prediksi model pada dataset pengujian ditunjukkan pada Gambar 3.



Gambar 3. Confusion Matrix Model pada Dataset Uji


Dari confusion matrix dapat diketahui bahwa kelas Healthy dan Fruit Rot memiliki tingkat klasifikasi tertinggi (>92%). Sementara itu, kelas Mealybug Wilt menunjukkan recall yang lebih rendah (85%) karena gejala visualnya mirip dengan Root Rot. Meski demikian, penambahan kelas Unknown terbukti efektif dalam mencegah salah klasifikasi citra non-nanas, sehingga meningkatkan robustnes sistem.

3.4 Hasil Implementasi Aplikasi

Hasil akhir penelitian ini berupa aplikasi diagnosis penyakit nanas berbasis Gradio. Aplikasi ini memungkinkan pengguna untuk mengunggah citra daun nanas dan memperoleh hasil prediksi secara langsung. Output yang ditampilkan berupa nama kelas penyakit (Healthy, Fruit Rot, Root Rot, Mealybug Wilt, atau Unknown), nilai confidence score, serta informasi singkat mengenai penyakit dan rekomendasi penanganan.



Gambar 4. Antarmuka Aplikasi Gradio



Gambar 5. Hasil Prediksi di Aplikasi Gradio

Keberhasilan implementasi ini menunjukkan bahwa model MobileNetV3-Large yang dikembangkan tidak hanya valid secara teoretis, tetapi juga aplikatif dan siap digunakan pada kondisi nyata di lapangan. Kehadiran kelas Unknown meningkatkan keandalan aplikasi dengan mencegah kesalahan klasifikasi terhadap citra non-nanas. Dengan demikian, aplikasi ini berpotensi membantu petani dalam melakukan deteksi dini penyakit nanas secara cepat, efisien, dan berbasis teknologi cerdas.

3.5 Perbandingan dengan Penelitian terdahulu

Perbandingan dengan beberapa penelitian relevan ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan Hasil Penelitian dengan Studi Terdahulu

Peneliti	Komoditas	Metode/Arsitektur	Akurasi/Temuan	Keterbatasan
Rahman &Pratiwi [5]	Tomat, Anggur	VGG-16	Akurasi >90%	Dataset terbatas, tanpa aplikasi
Linli et al. [7]	Tomat	ResNet-50 + Attention	Akurasi 98,10%	Data laboratorium, kurang variatif
Saddami et al. [11]	Padi	EfficientNet-B0	Akurasi lebih tinggi dibanding CNN konvensional	Dataset terbatas
Kumar et al. [15]	Jagung	CNN + Mobile App	Implementasi real-time di aplikasi mobile	Tidak ada kelas unknown
Penelitian ini	Nanas (Prabumulih)	MobileNetV3-Large + Transfer Learning	Akurasi validasi 91%, F1-score 90%, aplikasi Gradio	Dataset terbatas (3.500 citra)

Dari tabel terlihat bahwa penelitian ini unggul dalam hal akurasi (91%) serta kebaruan berupa penambahan kelas *unknown* dan implementasi model ke dalam aplikasi Gradio. Hal ini menjadikan penelitian lebih aplikatif dibandingkan penelitian terdahulu yang hanya berfokus pada pengembangan model.

3.6 Pembahasan

Hasil penelitian menunjukkan bahwa arsitektur MobileNetV3-Large mampu memberikan performa yang baik dalam klasifikasi penyakit tanaman nanas dengan akurasi validasi 91% dan F1-score 90%. Beberapa poin penting dapat dibahas sebagai berikut:

- Kinerja Model**
Model mampu menjaga konsistensi hasil pada data validasi (91%) dan pengujian (90%), yang membuktikan kemampuan generalisasi terhadap data baru. Performa ini menunjukkan bahwa strategi pelatihan dua tahap (feature extraction dan fine-tuning) efektif dalam meningkatkan akurasi pada dataset terbatas.
- Analisis Per Kelas**
Confusion matrix mengindikasikan bahwa kelas Healthy dan Fruit Rot memiliki tingkat klasifikasi yang tinggi (>92%). Sementara itu, kelas Mealybug Wilt cenderung mengalami kesalahan prediksi karena memiliki gejala visual yang mirip dengan Root Rot. Temuan ini selaras dengan laporan [16], yang menyoroti kesulitan membedakan penyakit dengan gejala yang serupa.
- Kebaruan Penelitian**
Penelitian ini menambahkan kelas Unknown, yang tidak ditemukan pada penelitian terdahulu. Kehadiran kelas ini menjadikan model lebih robust karena mampu menolak citra non-nanas atau citra yang tidak sesuai dengan kategori penyakit yang telah ditentukan.
- Perbandingan dengan Penelitian Terdahulu**
Jika dibandingkan dengan penelitian sebelumnya pada komoditas hortikultura lain [7], [11], [15], akurasi penelitian ini lebih tinggi (91% vs 85–89%). Selain itu, penelitian ini tidak hanya berhenti pada pembangunan model, tetapi juga menghadirkan aplikasi diagnosis berbasis Gradio yang dapat digunakan secara langsung oleh petani.

e. Keterbatasan dan Arah Penelitian Lanjutan

Meskipun model menunjukkan performa tinggi, ukuran dataset yang digunakan masih relatif terbatas (3.500 citra). Penelitian berikutnya dapat memperbesar variasi data lapangan dengan kondisi pencahayaan, sudut pengambilan gambar, dan jenis penyakit yang lebih beragam. Selain itu, eksplorasi arsitektur ringan lain seperti EfficientNetV2 dapat dipertimbangkan untuk meningkatkan akurasi sekaligus efisiensi komputasi.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi penyakit tanaman nanas berbasis citra digital dengan pendekatan *transfer learning* menggunakan arsitektur MobileNetV3-Large, yang menghasilkan akurasi validasi sebesar 91% dan F1-score 90% serta akurasi pengujian 90%. Kebaruan penelitian ini terletak pada penambahan kelas *Unknown* untuk meningkatkan robustnes model, strategi pelatihan dua tahap (*feature extraction* dan *fine-tuning*), serta implementasi aplikasi berbasis Gradio yang memudahkan pengguna dalam melakukan diagnosis penyakit secara langsung. Hasil ini membuktikan bahwa model yang dibangun tidak hanya efektif secara teoretis tetapi juga aplikatif untuk mendukung praktik pertanian presisi, meskipun masih diperlukan pengembangan dataset yang lebih beragam dan pengujian arsitektur lain pada penelitian berikutnya.

DAFTAR PUSTAKA

- [1] BPS Sumsel, *STATISTIK HARGA PRODUSEN SEKTOR PERTANIAN PROVINSI SUMATERA SELATAN 2023*, vol. Vol 14. Badan Pusat Statistik Provinsi Sumatera Selatan, 2024.
- [2] A. Soler, C. Pochat, M. Perrin, J. Mendoza, and F. Latchimy, "Systemic Acquired Resistance: Plant Priming for Ecological Management of Mealybug-Induced Wilt in MD2 and Queen Victoria Pineapples," *Agriculture* 2025, Vol. 15, Page 264, vol. 15, no. 3, p. 264, Jan. 2025, doi: 10.3390/AGRICULTURE15030264.
- [3] C. Jiang, X. Guo, Y. Li, N. Lai, L. Peng, and Q. Geng, "Multimodal Deep Learning Models in Precision Agriculture: Cotton Yield Prediction Based on Unmanned Aerial Vehicle Imagery and Meteorological Data," *Agronomy* 2025, Vol. 15, Page 1217, vol. 15, no. 5, p. 1217, May 2025, doi: 10.3390/AGRONOMY15051217.
- [4] P. F. Johari, N. Arifin, M. Muzaki, and M. S. A. Utama, "Corn Leaf Diseases Classification Using CNN with GLCM, HSV, and L*a*b* Features," *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 2, pp. 709–722, Apr. 2025, doi: 10.52436/1.JUTIF.2025.6.2.4345.
- [5] F. F. Rahman and N. Pratiwi, "IDENTIFIKASI PENYAKIT TUMBUHAN TOMAT DAN ANGGUR MENGGUNAKAN CNN DENGAN ARSITEKTUR VGG-16," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 10, no. 1, pp. 270–279, Jan. 2025, doi: 10.29100/JUPI.V10I1.5663.
- [6] M. Shoaib *et al.*, "A deep learning-based model for plant lesion segmentation, subtype identification, and survival probability estimation," *Front Plant Sci*, vol. 13, Dec. 2022, doi: 10.3389/FPLS.2022.1095547.
- [7] P. Linli, T. W. Sen, H. Fahmi, and R. Roestam, "Tomato Pest and Disease Identification Based on Improved Deep Residual Network and Transfer Learning," *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 8, no. 1, pp. 187–200, Mar. 2025, doi: 10.24014/IJAIDM.V8I1.34038.
- [8] S. Srinivasan, L. Somasundharam, S. Rajendran, V. P. Singh, S. K. Mathivanan, and U. Moorthy, "DBA-ViNet: an effective deep learning framework for fruit disease detection

- and classification using explainable AI,” *BMC Plant Biol*, vol. 25, no. 1, pp. 1–25, Dec. 2025, doi: 10.1186/S12870-025-07015-6/FIGURES/12.
- [9] Herimanto, A. S. Dharma, J. Amalia, D. Largo, and C. A. P. Sihite, “Performance Analysis of MobileNetV3-based Convolutional Neural Network for Facial Skin Disorder Classification,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 8, no. 6, pp. 701–709, Dec. 2024, doi: 10.29207/RESTI.V8I6.5982.
 - [10] X. Xu, J. Yang, W. Shi, S. Ding, L. Luo, and J. Liu, “PhysAug: A Physical-guided and Frequency-based Data Augmentation for Single-Domain Generalized Object Detection,” *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 39, no. 20, pp. 21815–21823, Dec. 2024, doi: 10.1609/aaai.v39i20.35487.
 - [11] K. Saddami, Y. Nurdin, M. Zahramita, and M. S. Safiruz, “Advancing Green AI: Efficient and Accurate Lightweight CNNs for Rice Leaf Disease Identification,” Aug. 2024, Accessed: Sep. 17, 2025. [Online]. Available: <https://arxiv.org/pdf/2408.01752>
 - [12] A. Fuentes, S. Yoon, S. C. Kim, and D. S. Park, “A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition,” *Sensors 2017, Vol. 17, Page 2022*, vol. 17, no. 9, p. 2022, Sep. 2017, doi: 10.3390/S17092022.
 - [13] K. P. Ferentinos, “Deep learning models for plant disease detection and diagnosis,” *Comput Electron Agric*, vol. 145, pp. 311–318, Feb. 2018, doi: 10.1016/J.COMPAG.2018.01.009.
 - [14] A. Khamparia, P. K. Singh, P. Rani, D. Samanta, A. Khanna, and B. Bhushan, “An internet of health things-driven deep learning framework for detection and classification of skin cancer using transfer learning,” *Transactions on Emerging Telecommunications Technologies*, vol. 32, no. 7, p. e3963, Jul. 2021, doi: 10.1002/ETT.3963.
 - [15] A. Kumar, H. P. Monga, T. Brahma, S. Kalra, and N. Sherif, “Mobile-Friendly Deep Learning for Plant Disease Detection: A Lightweight CNN Benchmark Across 101 Classes of 33 Crops,” Aug. 2025, Accessed: Sep. 17, 2025. [Online]. Available: <https://arxiv.org/pdf/2508.10817>