

Penerapan Arsitektur Vision Transformer (ViT) Berbasis Low-Code untuk Klasifikasi Penyakit Padi

Lucky Jayadinata¹, Giga Lukman Maulana², Tri Herdiawan Apandi³, Willy Muhammad Fauzi⁴
Program Studi Teknologi Rekayasa Perangkat Lunak / Jurusan Teknologi Informasi dan Komputer
Politeknik Negeri Subang

luckyjayadinata05@gmail.com; giga.lukman@gmail.com; tri@posub.ac.id; willy.fauzi@posub.ac.id

Blok Kaleng Banteng Desa Cibogo, Kec. Cibogo, Kabupaten Subang, Jawa Barat 41285.

Keywords:

Computer Vision;
Roboflow; Rice Disease
Classification; Vision
Transformer; Deep
Learning.

Abstract

Rice plant diseases can significantly reduce productivity and threaten food security, making early and accurate detection essential. Traditional manual inspection methods are slow, subjective, and difficult to scale for field conditions. This study aims to develop a rice disease classification system using computer vision and the low-code Roboflow platform with the Vision Transformer (ViT) architecture. The Rice Diseases Image Dataset, consisting of four classes – BrownSpot, Healthy, Hispa, and LeafBlast – underwent preprocessing, data augmentation, and splitting before being trained using the ViT model. The best-performing model (Version 6) achieved an accuracy of 92,2% on the test set. The results demonstrate that the proposed low-code workflow effectively streamlines the deployment pipeline of rice disease classification models, achieving competitive performance suitable for rapid prototyping in precision agriculture. These findings provide an initial foundation for the application of computer vision technologies in supporting precision agriculture practices.

Kata Kunci:

Computer Vision;
Roboflow; Klasifikasi
Penyakit Padi; Vision
Transformer; Deep
Learning.

Abstrak

Penyakit pada tanaman padi dapat menurunkan produktivitas dan mengancam ketahanan pangan, sehingga deteksi dini yang akurat menjadi sangat penting. Metode identifikasi manual cenderung lambat, subjektif, dan sulit diterapkan secara luas di lapangan. Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit padi berbasis computer vision menggunakan platform low-code Roboflow dengan arsitektur Vision Transformer (ViT). Dataset Rice Diseases Image Dataset yang terdiri dari empat kelas BrownSpot, Healthy, Hispa, dan LeafBlast diproses melalui tahap preprocessing, augmentasi, dan pembagian data sebelum dilatih menggunakan model ViT. Model terbaik (Versi 6) menghasilkan akurasi sebesar 92,2% pada data uji. Hasil penelitian menunjukkan bahwa pendekatan low-code yang diusulkan efektif dalam mengefisienkan siklus pengembangan model klasifikasi penyakit padi, dengan capaian performa yang kompetitif untuk kebutuhan prototyping cepat dalam pertanian presisi. Temuan ini memberikan landasan awal bagi implementasi teknologi visi komputer dalam mendukung praktik pertanian presisi.

1. Pendahuluan

Padi merupakan pangan pokok yang sangat penting bagi ketahanan pangan global. Namun, produksinya terus menghadapi ancaman serius dari berbagai penyakit tanaman, di mana rice plant diseases significantly reduce productivity and can threaten food security[1], sehingga deteksi dini menjadi sangat penting untuk mencegah kerugian panen yang besar. Dalam konteks Indonesia, deteksi dini sangat krusial karena identifikasi dan deteksi dini penyakit pada tanaman padi menjadi hal yang sangat penting untuk menjaga keberlanjutan dan efisiensi produksi pertanian[1].

Metode deteksi visual tradisional yang dilakukan oleh agronom maupun petani memiliki banyak keterbatasan. Pemeriksaan manual memakan waktu dan sangat dipengaruhi kondisi lingkungan, sebagaimana dijelaskan bahwa *physical inspection of plant diseases takes time due to multiple factors and environmental conditions* [2]. Selain lambat, metode ini juga bersifat subjektif dan rentan kesalahan, karena *traditional visual inspection is often inaccurate and inconsistent under varying field conditions* [2], sehingga tidak scalable untuk area pertanian yang luas.

Seiring dengan kemajuan teknologi pada bidang computer vision dan deep learning, pengenalan citra menggunakan Convolutional Neural Network (CNN) telah menjadi salah satu metode yang efektif untuk proses identifikasi dan klasifikasi citra tanaman secara otomatis. CNN merupakan model deep learning yang mampu melakukan ekstraksi fitur dan klasifikasi gambar secara efisien [3]. Namun demikian, proses pengembangan model CNN memerlukan tahapan yang kompleks, seperti pra-proses data, augmentasi citra, serta penyesuaian arsitektur dan parameter model untuk mencapai performa terbaik [4].

Tantangan dalam implementasi teknologi deteksi penyakit tanaman mendorong penggunaan platform berbasis AI yang lebih mudah diakses oleh praktisi non-programmer. Hal ini sejalan dengan temuan bahwa pengembangan model computer vision tradisional sering membutuhkan teknologi artificial intelligence (AI) yang dapat meningkatkan akurasi dan efisiensi dalam mendeteksi penyakit tanaman [5] serta proses manual yang memiliki keterbatasan pada akurasi dan efisiensi [6].

Platform low-code/no-code seperti Roboflow menjadi relevan karena mengurangi hambatan teknis tersebut. Pendekatan ini sejalan dengan kebutuhan praktisi untuk solusi yang memungkinkan proses identifikasi penyakit dilakukan dengan lebih cepat dan akurat [5] dan mendukung percepatan pembuatan model yang sebelumnya memerlukan pemahaman mendalam tentang arsitektur CNN yang memiliki kedalaman jaringan besar dan sering digunakan dalam pengenalan citra [6].


Penelitian sebelumnya memang telah mengevaluasi berbagai pendekatan otomatis untuk diagnosis penyakit tanaman, namun penerapannya pada skenario agrikultur presisi yang kompleks masih terus berkembang. Sebagaimana dijelaskan bahwa *the automatic diagnosis of rice diseases has encountered some practical problems because of the high complexity of rice disease symptoms under field conditions* [7], sehingga masih terdapat ruang eksplorasi lebih lanjut dalam pengembangan sistem yang benar-benar siap diterapkan di lapangan. Selain itu, studi tersebut menegaskan bahwa dataset dan konfigurasi kelas sangat memengaruhi performa model CNN, dimana *similar lesions are sometimes difficult to differentiate even for human experts* [7]. Temuan ini memperlihatkan bahwa penyakit dengan gejala mirip—seperti Brown Spot dan Hispa—masih menimbulkan tantangan bagi model vision-based, terutama ketika diterapkan pada citra lapangan yang kompleks [8].

Untuk mengatasi permasalahan tersebut, penelitian ini bertujuan untuk merancang, membangun, dan mengevaluasi kinerja sistem visi komputer untuk identifikasi penyakit padi dengan memanfaatkan platform Roboflow [9]. Sistem dikembangkan dan divalidasi menggunakan dataset citra publik Rice Diseases Image Dataset. Kontribusi utama dari penelitian ini terletak pada penyajian studi implementasi end-to-end yang transparan, terstruktur, dan dapat direplikasi, sehingga mampu memberikan acuan kinerja (benchmark) yang praktis bagi pengembang sistem agrikultur presisi yang ingin memanfaatkan teknologi AI berbasis low-code untuk percepatan pengembangan (rapid deployment) di lapangan [10].

Beberapa studi lokal telah menerapkan arsitektur Transformer (ViT, CCT) pada klasifikasi penyakit tanaman dan melaporkan peningkatan stabilitas serta kemampuan generalisasi terhadap variasi pencahayaan dan tekstur daun [11].

2. Metodologi Penelitian

Metode penelitian ini disusun untuk menggambarkan tahapan dalam merancang, membangun, dan mengevaluasi model klasifikasi penyakit padi berbasis computer vision menggunakan platform low-code Roboflow. Secara umum, alur penelitian mencakup tiga tahap utama, yaitu: (1) Persiapan Dataset dan Augmentasi, (2) Pelatihan Model, dan (3) Evaluasi Kinerja Model. Alur lengkap penelitian ditunjukkan pada Gambar 1.



Gambar 1. 1 Alur Kerja Penelitian

2.1. Persiapan Dataset dan Augmentasi

Dataset yang digunakan dalam penelitian ini adalah *Rice Diseases Image Dataset* dari *Kaggle*, yang terdiri atas empat kelas daun padi, yaitu: *BrownSpot*, *Healthy*, *Hispa*, dan *LeafBlast*. Total dataset sumber berjumlah 6.247 citra, dengan variasi kondisi pencahayaan dan tampilan daun yang beragam.

Dataset diunggah ke dalam proyek *Roboflow* untuk menjalani proses *preprocessing* dan augmentasi sebagai berikut:

a. *Preprocessing*

1. *Auto-Orient* untuk memastikan orientasi citra sesuai metadata.
2. *Resize* (224×224 px, *Stretch*) untuk menyeragamkan ukuran input model.

b. Augmentasi Data

Untuk meningkatkan keragaman dataset serta mengurangi risiko *overfitting*, diterapkan beberapa teknik augmentasi, yaitu:

1. *Flip* (*horizontal* dan *vertikal*)
2. *Rotation* (-15° hingga $+15^\circ$)

3. Brightness Adjustment (−15% hingga +15%)

Setiap citra latih menghasilkan tiga variasi augmentasi, sehingga dataset meningkat menjadi 8.052 citra. Dataset kemudian dibagi menjadi tiga subset:

1. Data latih (*Train*): 88%
2. Validasi (*Validation*): 8%
3. Uji (*Test*): 4%

Seluruh pengolahan dataset pada tahap ini dilakukan menggunakan modul Roboflow Dataset Management. Pembagian dataset ditampilkan pada Gambar 2.



Gambar 1. Pembagian Dataset

Untuk memberikan gambaran visual mengenai variasi citra pada setiap kelas penyakit, Tabel 1 berikut menyajikan contoh gambar dari masing-masing jenis penyakit yang terdapat dalam dataset Rice Diseases Image. Setiap kelas memiliki karakteristik visual yang unik, seperti perubahan warna, bercak, garis nekrosis, serta deformasi jaringan daun yang menjadi indikator utama keberadaan penyakit.

Tabel 1. Tabel Gambar Kelas Penyakit Daun Padi

BrownSpot	Healthy	Hispa	LeafBlast
			

2.2. Pelatihan Model

Pelatihan model dilakukan menggunakan layanan *Roboflow Cloud Training* dengan arsitektur *Vision Transformer (ViT) Classification*. Pemilihan ViT didasarkan pada kemampuannya mengekstraksi pola visual berbasis patch yang terbukti efektif pada tugas klasifikasi citra kompleks[12]. Pemilihan ViT juga didukung oleh studi lokal yang menemukan ViT (dan varian CCT) efektif untuk tugas klasifikasi penyakit padi pada dataset citra daun, terutama untuk menghadapi variasi kondisi lapang dan perbedaan tekstur antar kelas penyakit [11]. Dengan dukungan implementasi ViT pada *Roboflow*, proses pengembangan model menjadi lebih cepat dan stabil. Selain itu, Roboflow menyediakan implementasi ViT yang siap digunakan tanpa perlu konfigurasi manual, sehingga mempercepat proses eksperimen.

Lingkungan pelatihan mencakup:

- GPU Cloud Roboflow (spesifikasi internal tidak dipublikasikan),
- Optimizer, learning rate, dan batch size mengikuti konfigurasi default Roboflow untuk ViT Classification,
- Total pelatihan: 27 epochs.

Beberapa konfigurasi augmentasi diuji dalam beberapa eksperimen internal. Model dengan performa terbaik adalah Model Versi 6, yang kemudian dipilih sebagai final model.

Selama pelatihan, Roboflow menghasilkan grafik Training Loss dan Validation Accuracy untuk memantau konvergensi model.

Secara keseluruhan, kombinasi training loss yang menurun stabil dan validation accuracy yang konsisten menunjukkan bahwa model ViT Version 6 telah terlatih dengan baik dan memiliki kemampuan generalisasi yang memadai. Hal ini sejalan dengan hasil evaluasi akhir yang menghasilkan akurasi 92,2% pada test set, mencerminkan performa yang cukup kompetitif untuk klasifikasi penyakit padi berbasis citra.

2.3. Evaluasi Kinerja

Evaluasi performa dilakukan menggunakan test set sebesar 4% dari dataset total. Metrik utama yang digunakan adalah akurasi, dihitung dengan Persamaan (1):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$


dengan: TP : *True Positive*, TN: *True Negative*, FP: *False Positive*, FN: *False Negative*.

Platform Roboflow secara otomatis menghitung akurasi akhir model. Berdasarkan hasil evaluasi, Model ViT Versi 6 mencapai akurasi sebesar 92,2% pada *test set*. Hasil ini selanjutnya dianalisis lebih lanjut pada bagian Hasil dan Pembahasan. Mengingat batasan akses pada metrik evaluasi mendalam di platform Roboflow, penelitian ini menerapkan prosedur validasi eksternal. Data hasil prediksi (*inference results*) dari model terhadap 335 citra *test set* diekstraksi untuk dianalisis secara independen. Perhitungan metrik performa (*Accuracy*, *Precision*, *Recall*, *F1-Score*) dan penyusunan Matriks Kebingungan (*Confusion Matrix*) dilakukan menggunakan perhitungan statistik standar dengan membandingkan label prediksi terhadap label sebenarnya (*ground truth*). Pendekatan ini memastikan objektivitas evaluasi kinerja model. Selain itu, fitur ekspor bobot (*weights export*) untuk model *ViT Classification* belum didukung pada saat penelitian dilakukan, sehingga validasi eksternal menggunakan framework lain seperti *TensorFlow* atau *PyTorch* tidak dapat dilakukan. Oleh karena itu, evaluasi fokus pada metrik akurasi yang tersedia serta analisis kualitatif berdasarkan log pelatihan.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pelatihan Model


Pelatihan model dilakukan pada platform Roboflow menggunakan arsitektur *Vision Transformer (ViT) Classification*. Dari beberapa eksperimen augmentasi, model terbaik adalah versi 6, yang dilatih selama 27 epochs. Grafik *Training Loss* menunjukkan penurunan yang konsisten, sedangkan *Validation Accuracy* cenderung stabil pada akhir proses pelatihan. Hal ini menunjukkan bahwa model tidak mengalami *overfitting* signifikan.



Gambar 2. Grafik Training Loss

Pada gambar 3 menunjukkan penurunan yang konsisten dari epoch awal hingga akhir. Penurunan cepat pada beberapa epoch pertama menandakan bahwa model ViT mampu mempelajari pola dasar citra dengan efektif. Meski terdapat sedikit lonjakan pada beberapa epoch, nilai loss kembali stabil dan

mendekati nol pada akhir pelatihan, mengindikasikan bahwa proses pembelajaran berjalan optimal tanpa tanda overfitting yang signifikan.



Gambar 3. Grafik Validation Accuracy

Pada gambar 4 berfluktuasi dalam rentang 0.78–0.82, namun tetap menunjukkan stabilitas kinerja model pada data yang belum pernah dilihat. Fluktuasi tersebut wajar mengingat kemiripan gejala antar kelas penyakit padi seperti Brown Spot, Leaf Blast, dan Hispa. Penurunan akurasi pada titik tertentu kembali pulih pada epoch akhir, menunjukkan bahwa model mampu mempertahankan generalisasi yang baik.

Meskipun akurasi validasi selama pelatihan berkisar di 82%, pengujian akhir pada data uji (Test Set) terpisah menunjukkan performa yang lebih tinggi mencapai **92,2%**, mengindikasikan model memiliki generalisasi yang sangat baik.

3.2. Evaluasi Kinerja Model

Evaluasi dilakukan menggunakan data uji sebesar 4% dari total dataset. Kinerja model diukur menggunakan metrik akurasi pada data uji. Perhitungan akurasi menggunakan Persamaan (1):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Hasil pengujian ditunjukkan pada Tabel 2.

Tabel 1. Tabel Perbandingan Kinerja Model

Model ID	Versi Dataset	Akurasi(Accuracy)	Status
kelompok-2-datamining-iyz0c/1	V1 (Original)	74.9%	Baseline (Model Dasar/Tanpa Augmentasi)
kelompok-2-datamining-iyz0c/2	V2 (Augmented)	79.0%	Diuji
kelompok-2-datamining-iyz0c/3	V3 (Augmented)	81.1%	Diuji
kelompok-2-datamining-iyz0c/4	V4 (Augmented)	84.4%	Diuji
kelompok-2-datamining-iyz0c/4	V5 (Augmented)	92.2%	Model Terbaik (Akurasi Tertinggi)

Tabel 2. Hasil Evaluasi Model ViT (Versi 5)

Metrik Evaluasi	Nilai
Akurasi	92,2%
Total Data Uji	335 citra
Jumlah Kelas	4 kelas (BrownSpot, Healthy, Hispa, LeafBlast)

Untuk memvalidasi performa model secara mendalam di luar estimasi platform, dilakukan perhitungan metrik secara independen pada data hasil inferensi. Analisis ini menghasilkan rincian performa per kelas yang lebih spesifik.

Model ViT (Versi 6) menunjukkan performa klasifikasi yang cukup baik untuk empat kelas penyakit padi. Akurasi tertinggi dicapai pada kelas *Healthy* dan *LeafBlast*, karena kedua kelas tersebut memiliki pola visual yang lebih konsisten dan mudah dibedakan oleh model. Sementara itu, masih ditemukan kesalahan klasifikasi pada kelas *BrownSpot* dan *Hispa*, terutama disebabkan oleh kemiripan tekstur bercak pada kedua kelas tersebut yang membuat model sesekali mengalami ambiguitas dalam proses pengenalan.

Detail performa klasifikasi dapat dilihat pada matriks kebingungan (confusion matrix) yang disajikan dalam **Tabel 2**.

Tabel 3. Confusion Matrix Model ViT (v6) pada Data Uji

Kelas Sebenarnya \ Prediksi	BrownSpot	Healthy	Hispa	Leaf Blast	Total
BrownSpot	46	3	4	0	53
Healthy	0	96	1	3	100
Hispa	1	1	81	7	90
Leaf Blast	0	4	2	86	92
Total Prediksi	47	104	88	96	335

Selain akurasi global, performa model juga diukur menggunakan metrik *Precision*, *Recall*, dan *F1-Score* untuk setiap kelas penyakit sebagaimana tersaji pada Tabel 4.

Table 4. Performa Model Berdasarkan Kelas

Kelas	Precision	Recall	F1-Score
BrownSpot	97.9%	86.8%	92.0%
Healthy	92.3%	96.0%	94.1%
Hispa	92.0%	90.0%	91.0%
LeafBlast	89.6%	93.5%	91.5%
Rata-rata	92.9%	91.6%	92.1%

Berdasarkan hasil inferensi (bagian *Output*) pada Gambar 5 menunjukkan bahwa model berhasil mengidentifikasi kelas penyakit pada citra uji dengan benar. Adapun rincian prediksi adalah sebagai berikut:

- Kelas Prediksi: *BrownSpot*
- Tingkat Keyakinan (*Confidence Score*): 0.9426 (94,26%)

Tingkat keyakinan yang tinggi ini menunjukkan bahwa model telah mempelajari pola visual khas dari penyakit *Brown Spot*, sehingga mampu melakukan klasifikasi dengan tingkat ambiguitas yang rendah. Selain itu, data JSON yang dihasilkan juga mencakup informasi seperti *class_id*, nilai *confidence*, serta metadata inferensi yang tersusun rapi. Hal ini mengindikasikan bahwa model siap untuk digunakan dalam integrasi layanan berbasis API, karena sudah menyediakan struktur output yang lengkap dan mudah diolah pada tahap *deployment*.

3.3. Analisis Pembahasan

"Berdasarkan pengujian pada 335 citra baru, model mencapai akurasi total sebesar 92,2%, meningkat signifikan dibandingkan hasil awal. Meskipun proporsi data uji pada penelitian ini ditetapkan sebesar 4%, jumlah absolut 335 citra dianggap representatif secara statistik untuk menguji variasi visual utama

antar kelas, mengingat dataset telah melalui proses augmentasi yang ketat. Tabel Confusion Matrix menunjukkan bahwa model sangat tangguh dalam mengenali kelas Healthy (F1-Score 94.1%). Kesalahan klasifikasi minor terjadi antara kelas Hispa dan LeafBlast, di mana 7 citra Hispa diprediksi sebagai LeafBlast. Hal ini dapat dikaitkan dengan kemiripan visual pola nekrosis pada tahap lanjut kedua penyakit tersebut. Meskipun demikian, nilai presisi yang tinggi (>89%) pada seluruh kelas menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik untuk penerapan di lapangan.

Model Vision Transformer (ViT) Versi 6 memperoleh akurasi sebesar **92,2%**, yang menunjukkan kinerja yang cukup kompetitif dalam mengklasifikasikan empat kelas penyakit padi. Meskipun evaluasi hanya menggunakan metrik akurasi akibat keterbatasan platform, hasil ini sudah mampu menggambarkan kemampuan model dalam membedakan daun padi sehat dan terinfeksi.

a. Pengaruh Augmentasi Data

Teknik augmentasi berupa *flip*, rotasi, dan penyesuaian kecerahan terbukti meningkatkan keragaman data latih, sehingga membantu model beradaptasi terhadap variasi kondisi lapangan seperti perubahan pencahayaan dan orientasi daun. Hal ini tercermin dari *training loss* yang menurun secara stabil tanpa menunjukkan gejala *overfitting*. Dengan demikian, augmentasi berperan penting dalam meningkatkan kualitas pembelajaran model.

b. Kinerja Vision Transformer (ViT)

Arsitektur ViT menunjukkan performa yang stabil pada data validasi, meskipun dataset memiliki kemiripan visual antar kelas. Mekanisme attention yang bekerja pada level patch memungkinkan model mengekstraksi informasi tekstur dan pola bercak secara lebih efektif dibandingkan arsitektur CNN konvensional. Stabilitas validation accuracy mengindikasikan bahwa ViT memiliki kemampuan generalisasi yang baik terhadap data baru.

c. Efektivitas Platform Roboflow

Roboflow memfasilitasi keseluruhan proses mulai dari pra-pemrosesan data, augmentasi, pelatihan, hingga evaluasi model dalam lingkungan low-code. Hal ini mempermudah proses eksperimen dan mempercepat iterasi model tanpa memerlukan konfigurasi kompleks. Kemudahan ini sangat mendukung pengembangan prototipe model berbasis computer vision secara cepat dan efisien.

d. Tantangan dan Keterbatasan

Kesalahan klasifikasi terutama ditemukan pada kelas BrownSpot dan Hispa, yang memiliki kemiripan pola visual seperti bercak dan perubahan warna daun. Dataset publik yang digunakan juga belum sepenuhnya merepresentasikan kondisi lapangan, sehingga kinerja model pada aplikasi nyata masih memerlukan pengujian tambahan.

Secara keseluruhan, hasil penelitian menunjukkan bahwa ViT dan platform Roboflow memiliki potensi besar untuk mendukung pengembangan sistem deteksi penyakit padi berbasis computer vision, terutama untuk pengembangan cepat dan implementasi awal dalam sektor pertanian presisi.

4. KESIMPULAN DAN SARAN

4.1. Kesimpulan

Penelitian ini berhasil membangun model klasifikasi penyakit padi berbasis Vision Transformer (ViT) menggunakan platform Roboflow dan mencapai akurasi 92,2% pada data uji. Hasil ini menunjukkan bahwa ViT efektif dalam mengenali pola visual penyakit daun padi, sementara augmentasi data berkontribusi pada peningkatan generalisasi model. Roboflow mempermudah proses pengolahan data dan pelatihan secara low-code, meskipun keterbatasan metrik evaluasi dan ekspor bobot model membatasi analisis lanjutan. Secara keseluruhan, penelitian ini memberikan dasar yang kuat untuk pengembangan sistem deteksi penyakit padi berbasis computer vision di masa depan.

4.2. Saran

- Penelitian berikutnya disarankan menggunakan *platform* atau *framework* yang menyediakan metrik evaluasi lengkap
- Pengumpulan data citra langsung dari lahan pertanian dengan variasi kondisi lingkungan diperlukan agar model mampu beradaptasi terhadap kondisi nyata dan meningkatkan kemampuan generalisasinya.
- Pemanfaatan API *Roboflow* memungkinkan pengembangan aplikasi deteksi penyakit berbasis *web* atau *mobile* sehingga dapat digunakan secara langsung oleh petani atau penyuluh pertanian.

REFERENSI

- [1] B. K. Gulo, R. Agustinus, and J. Himamunanto, "BULLETIN OF COMPUTER SCIENCE RESEARCH Deteksi Penyakit Tanaman Padi (*Oryza Sativa* L.) Menggunakan Support Vector Machine (SVM) Dan Random Forest Pada Citra Daun," *Media Online*, vol. 5, no. 2, pp. 724–733, 2025, doi: 10.47065/bulletincsr.v5i4.660.
- [2] T. Agustin, I. A. Saputro, and M. L. Rahmadi, "Optimizing Rice Plant Disease Classification Using Data Augmentation with GANs on Convolutional Neural Networks," *INTENSIF: Jurnal Ilmiah Penelitian dan Penerapan Teknologi Sistem Informasi*, vol. 9, no. 1, pp. 97–114, Feb. 2025, doi: 10.29407/intensif.v9i1.23834.
- [3] B. Kusuma, T. I. Hermanto, and C. D. Lestari, "KLASIFIKASI JENIS PENYAKIT PADA TANAMAN PADI MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK," *JIKO (Jurnal Informatika dan Komputer)*, vol. 9, no. 1, p. 40, Feb. 2025, doi: 10.26798/jiko.v9i1.1395.
- [4] Shreyasi Bhattacharya Maulana Abul Kalam Azad University of Technology Anirban Mukherjee Santanu Phadikar, "Mybookchapter," 2020.
- [5] H. Nata Niko Pirnando and J. Petrus, "4 TH MDP STUDENT CONFERENCE (MSC) 2025 Universitas Multi Data Palembang | 207 Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network dengan Arsitektur AlexNet".
- [6] F. Angela Tanesab, R. Pahlevi Putra, and A. Yuniar Rahman, "Classification Of Rice Plant Diseases Based on Leaf Images Using the Multi Class Support Vector Machine (M-SVM) Method," *Buana Information Technology and Computer Sciences (BIT and CS)*, vol. 6, no. 2, 2025.
- [7] H. Zhou, J. Deng, D. Cai, X. Lv, and B. M. Wu, "Effects of Image Dataset Configuration on the Accuracy of Rice Disease Recognition Based on Convolution Neural Network," *Front Plant Sci*, vol. 13, Jul. 2022, doi: 10.3389/fpls.2022.910878.
- [8] P. S. Roy and V. Kukreja, "Vision transformers for rice leaf disease detection and severity estimation: a precision agriculture approach," *Journal of the Saudi Society of Agricultural Sciences*, vol. 24, no. 3, Jul. 2025, doi: 10.1007/s44447-025-00007-w.
- [9] M. S. Thesis and E. Guresci, "Low code development platforms for Precision Agriculture," 2025.
- [10] M. Dutta *et al.*, "Rice Leaf Disease Classification—A Comparative Approach Using Convolutional Neural Network (CNN), Cascading Autoencoder with Attention Residual U-Net (CAAR-U-Net), and MobileNet-V2 Architectures," *Technologies (Basel)*, vol. 12, no. 11, Nov. 2024, doi: 10.3390/technologies12110214.
- [11] T. Febriyanto and S. Syofian, "Implementasi Deep Learning Menggunakan Vision Transformer Untuk Klasifikasi Penyakit Daun Padi," *Journal TIFDA (Technology Information and Data Analytic)*, vol. 1, no. 2, pp. 34–39, Dec. 2024, doi: 10.70491/tifda.v1i2.47.

- [12] C. G. Simhadri, H. K. Kondaveeti, V. K. Vatsavayi, A. Mitra, and P. Ananthachari, "Deep learning for rice leaf disease detection: A systematic literature review on emerging trends, methodologies and techniques," Jun. 01, 2025, *China Agricultural University*. doi: 10.1016/j.inpa.2024.04.006.