

Klasifikasi Penyakit Daun Padi: Implementasi Arsitektur Vision Transformer (ViT) untuk Peningkatan Diagnosa

Dafina Azahra Ramadhani^{1*)}, Derivo Vicky Syaubilly², Tri Herdiawan Apandi³, Willy Muhammad Fauzi⁴,

¹²³⁴Jurusan Teknologi Informasi dan Komputer, Program Studi Rekayasa Perangkat Lunak,
Politeknik Negeri Subang, Subang

¹²³⁴Jln. Brigjen Katamso No.37, Dangdeur, Kec Subang, Kabupaten Subang, Jawa Barat 41211

email: ¹dafina.10601008@student.polsub.ac.id, ²derivo.10601010@student.polsub.ac.id,

³tri@polsub.ac.id, ⁴willy@polsub.ac.id

Abstract — Diseased rice leaf surfaces can drastically reduce crop yields. This study aims to explore the use of the Vision Transformer (ViT) architecture in identifying rice leaf diseases. The applied method is an experiment using a dataset of rice leaf images from the Roboflow platform that includes nine types of diseases. Trials were conducted to analyze the performance of ViT compared to a more traditional CNN architecture. The results showed that the ViT model can achieve 98.9% accuracy, higher than previous methods. This study emphasizes that the attention mechanism in ViT is effective in identifying subtle visual characteristics in agricultural images.

Abstrak – Permukaan daun padi yang terjangkit penyakit dapat mengurangi hasil panen secara drastis. Penelitian ini bertujuan untuk mengeksplorasi penggunaan arsitektur Vision Transformer (ViT) dalam mengidentifikasi penyakit pada daun padi. Metode yang diterapkan adalah eksperimen dengan memanfaatkan kumpulan data gambar daun padi dari platform Roboflow yang mencakup sembilan jenis penyakit. Uji coba dilakukan untuk menganalisis kinerja ViT dibandingkan dengan arsitektur CNN yang lebih tradisional. Hasil penelitian menunjukkan bahwa model ViT dapat mencapai akurasi 98,9%, yang lebih tinggi daripada metode sebelumnya. Penelitian ini menekankan bahwa mekanisme perhatian pada ViT efektif dalam mengidentifikasi ciri visual yang halus pada gambar pertanian.

Kata Kunci – Penyakit Daun Padi, Vision Transformer, Pertanian Presisi, Deep Learning.

*) penulis korespondensi: Dafina Azahra Ramadhani
Email: dafina.10601008@student.polsub.ac.id

I. PENDAHULUAN

Keberlangsungan sektor pertanian dan ketahanan pangan secara global terus menghadapi berbagai tantangan, salah satunya disebabkan oleh serangan berbagai penyakit tanaman. Padi (*Oryza sativa*), yang merupakan sumber makanan utama bagi lebih dari separuh penduduk dunia, sangat mudah terserang oleh patogen yang menyerang daunnya, seperti bakteri penyebab hawar daun dan bercak cokelat [1]. Penyakit-penyakit ini tidak hanya mengakibatkan penurunan jumlah hasil panen, tetapi juga berimbas pada kerugian finansial yang signifikan bagi petani di kawasan pertanian yang penting [2]. Penyakit pada tanaman padi yang tidak ditangani dengan cepat diperkirakan dapat mengakibatkan penurunan hasil panen hingga 70% dalam situasi yang sangat parah, yang secara langsung mengancam keamanan pangan di negara-negara yang sedang berkembang [3].

Selama ini, cara untuk mendeteksi penyakit umumnya dilakukan secara fisik dengan pengamatan langsung oleh ahli atau penyuluh lapangan. Akan tetapi, metode ini memiliki kelemahan yang signifikan: bersifat pribadi, memakan waktu, dan rentan terhadap kesalahan manusia, terutama saat gejala penyakit terlihat sangat mirip [4]. Keterlambatan dalam penegakan diagnosis sering kali membuat petani terpaksa menggunakan pestisida secara berlebihan, yang akhirnya berdampak buruk bagi lingkungan dan meningkatkan biaya produksi.

Sebagai solusi, teknologi Computer Vision yang didasarkan pada *Deep Learning* telah banyak digunakan. Arsitektur Convolutional Neural Network (CNN) telah menjadi standar utama dalam beberapa tahun terakhir karena kemampuannya dalam secara otomatis mengambil fitur dari citra [5],[6]. Sebagai contoh, penelitian terbaru yang dilakukan oleh Apriani, Adi, dan Widodo (2025) menggunakan model CNN untuk mengidentifikasi sembilan jenis penyakit pada daun padi dan berhasil mencapai tingkat akurasi pengujian sebesar 84,52%. Meskipun hasilnya cukup memuaskan, penelitian tersebut mengindikasikan bahwa ada tingkat kesalahan yang lebih tinggi dalam klasifikasi penyakit yang memiliki penampilan serupa, seperti Brown Spot dan Leaf Blast. Ini menunjukkan adanya batasan dalam kemampuan model untuk membedakan fitur yang saling tumpang tindih. Hal ini menunjukkan bahwa CNN menghadapi kelemahan intrinsik karena penekanan pada fitur lokal (konvolusi dari area kecil), yang sering kali kurang mampu memahami konteks keseluruhan atau hubungan jarak jauh antara elemen-elemen gambar yang krusial untuk mengidentifikasi lesi penyakit yang kompleks [7].

Untuk mengatasi masalah ini, studi ini memperkenalkan metode baru dengan memanfaatkan arsitektur Vision Transformer (ViT). Tidak seperti CNN, ViT menggunakan mekanisme self-attention yang memungkinkan model untuk menginterpretasikan gambar sebagai serangkaian patch, sehingga dapat mengidentifikasi fitur lokal dan global secara bersamaan [8]. Penelitian ini bertujuan untuk merancang dan menguji model klasifikasi penyakit pada daun padi yang menggunakan ViT dengan dataset gambar dari Indonesia, serta menunjukkan bahwa metode ini memberikan akurasi dan presisi yang lebih baik dibandingkan teknik tradisional untuk mendukung sistem pertanian pintar.


II. PENELITIAN YANG TERKAIT

Penelitian Studi terbaru oleh Apriani dan tim menciptakan sistem klasifikasi otomatis untuk penyakit pada daun padi dengan menggunakan arsitektur Convolutional Neural Network (CNN). Penelitian ini memanfaatkan dataset yang terdiri dari 15.030 gambar, mencakup sembilan jenis penyakit,

dan berhasil meraih akurasi pengujian sebesar 84,52% [7]. Walaupun mampu mengklasifikasikan penyakit dengan gejala yang jelas, model CNN tersebut mengalami penurunan kinerja pada penyakit yang memiliki kesamaan visual yang tinggi, seperti antara Brown Spot dan Leaf Blast, akibat kesulitan dalam membedakan fitur visual yang saling tumpang tindih. Perbedaan utama dari penelitian ini dibandingkan dengan studi sebelumnya terletak pada jenis arsitektur yang digunakan. Sementara studi sebelumnya menggunakan CNN yang menekankan ekstraksi fitur lokal, studi ini menerapkan Vision Transformer (ViT) yang memanfaatkan mekanisme self-attention. Pendekatan ini dipilih untuk mengatasi kelemahan CNN dalam memahami konteks global dari gambar, dengan harapan bisa meningkatkan ketepatan pada jenis penyakit yang serupa dan mencapai tingkat akurasi keseluruhan yang lebih baik. Artikel sekarang dan diusahakan dari jurnal internasional yang berdampak.

III. METODE PENELITIAN

Penelitian ini memiliki beberapa langkah penting, dimulai dari pengumpulan data, pemrosesan awal data, pelatihan model dengan menggunakan arsitektur Vision Transformer (ViT), hingga penilaian kinerja model. Proses penelitian dapat dilihat pada Gambar 1.



Gambar 1 Alur Penelitian

A. Pengumpulan Data

Dataset untuk penelitian ini diambil dari Kaggle – Rice Leaf Diseases Detection (loki4514) sebagai data sekunder. Dataset tersebut mencakup gambar daun padi yang dikategorikan dalam 9 jenis penyakit, yaitu Bacterial Leaf Blight, Brown Spot, Healthy Rice Leaf, Leaf Blast, Leaf Scald, Narrow Brown Leaf Spot, Neck Blast, Rice Hispa, dan Sheath Blight. Detail dataset deteksi penyakit daun padi disajikan pada Tabel 1 dan detail data split disajikan pada Tabel 2.

TABEL 1

DETAIL DATASET CITRA PENYAKIT DAUN PADI

Sampel	Jumlah Data	Sumber Data
Bacterial Leaf Blight	1.197	Kaggle
Brown Spot	1.537	Kaggle
Healthy Rice Leaf	1.082	Kaggle
Leaf Blast	1.713	Kaggle
Leaf Scald	1.332	Kaggle

Narrow Brown	954	Kaggle
Leaf Spot		
Neck Blast	1.000	Kaggle
Rice Hispa	1.299	Kaggle
Sheath Blight	1.625	Kaggle
Total	11.739	

TABEL 2
PEMBAGIAN DATA

Data Split	Persentase	Jumlah
Train Set	70%	8154
Valid Set	20%	2337
Test Set	10%	1168

Berikut contoh salah satu gambar dari setiap 9 kelas yaitu Bacterial Leaf Blight, Brown Spot, Healthy Rice Leaf, Leaf Blast, Leaf Scald, Narrow Brown Leaf Spot, Neck Blast, Rice Hispa, Sheath Blight.



Gambar 2 Dataset Citra Penyakit Daun

Pada Gambar 1, terdapat contoh sembilan tipe penyakit yang menyerang daun padi, yaitu Bacterial Leaf Blight yang terlihat dengan bercak panjang berwarna kuning kecoklatan, Brown Spot yang memiliki bercak oval berwarna coklat, daun yang sehat tampak berwarna hijau merata, Leaf Blast yang ditandai dengan bercak elips yang memiliki tepi coklat gelap, Leaf Scald yang bercak besarnya tidak beraturan, Narrow Brown Leaf Spot yang menunjukkan lesi sempit sejajar dengan urat daun, Neck Blast yang muncul di leher malai dengan warna coklat tua hingga hitam, Rice Hispa yang menampilkan garis putih akibat kerusakan oleh larva, dan Sheath Blight yang memiliki lesi besar dengan warna abu-abu keputihan.

B. Pra-pemrosesan Data


Tahap pra-pemrosesan data merupakan fase esensial dan kritis dalam setiap penelitian berbasis pengolahan citra dan pembelajaran mendalam (Deep Learning). Proses ini bertujuan untuk menertibkan, menstandarisasi, dan meningkatkan kualitas data mentah sebelum dimasukkan ke dalam model

klasifikasi Vision Transformer (ViT). Hal ini sangat penting karena kualitas citra masukan secara langsung menentukan akurasi dan kemampuan generalisasi model [9], mengingat bahwa kinerja suatu prototipe pengolahan citra di lapangan sangat dipengaruhi oleh kualitas tangkapan citra dan kondisi pencahayaan [10].

Untuk memenuhi kebutuhan klasifikasi Deep Learning yang komprehensif, dataset yang digunakan dalam penelitian ini mencakup 9 kelas yang mewakili spektrum luas penyakit dan kondisi daun padi, yaitu: Bacterial Leaf Blight, Brown Spot, Healthy Rice Leaf, Leaf Blast, Leaf Scald, Narrow Brown Leaf Spot, Neck Blast, Rice Hispa, dan Sheath Blight.

Tabel 2 menggambarkan rincian pembagian data. Train Set terdiri dari 8154 gambar yang digunakan untuk melatih model secara menyeluruh. Valid Set terdiri dari 2337 gambar yang dimanfaatkan untuk mengawasi performa model selama proses pelatihan serta membantu penyesuaian hyperparameter agar tidak terjadi overfitting. Terakhir, Test Set terdiri dari 1168 gambar. Test Set ini dijejalkan sepenuhnya terpisah dan hanya dipakai satu kali di fase akhir untuk memberikan penilaian kinerja model yang adil dan objektif.

Selanjutnya melakukan pembuatan model baru yang bertujuan mendapatkan tingkat akurasi yang lebih tinggi, model baru ini versi kedua dari model yang pertama dengan menambahkan dua augmentasi yaitu flip: horizontal dan rotation: antara -45° dan $+45^\circ$. Total train set menjadi 24415 gambar, valid tes 2337 gambar, test set 1168 gambar. Gambar detail dataset pada gambar 3. Penggunaan teknik augmentasi geometris semacam ini telah terbukti melalui pengamatan dapat mengurangi kemungkinan terjadinya overfitting dan memperbaiki kemampuan umum model dalam berbagai kondisi lingkungan pertanian[11].



Gambar 3 Detail Dataset

C. Klasifikasi

Tahap klasifikasi adalah langkah penting dalam studi ini yang bertujuan untuk mengidentifikasi dan mengelompokkan gambar daun padi ke dalam sembilan kategori penyakit berdasarkan pola dan karakteristik visual yang terdapat dalam gambar tersebut. Pelatihan dan pengujian dilaksanakan menggunakan arsitektur Vision Transformer (ViT) yang diterapkan melalui platform Roboflow untuk mengelola dataset dan mengintegrasikannya dengan model pembelajaran mendalam.

Vision Transformer (ViT) adalah sebuah struktur Deep Learning yang didasarkan pada transformer, yang diambil dari dunia Natural Language Processing (NLP) untuk keperluan pengenalan gambar. Berbeda dengan Convolutional Neural Network (CNN) yang mengambil fitur lokal dengan menggunakan filter konvolusi, ViT menangani gambar sebagai wilayah-wilayah kecil (image patches) dengan ukuran tetap. Setiap wilayah gambar diwakili sebagai vektor numerik (embedding) dan diperlakukan serupa dengan rangkaian token

dalam teks(Leonardi C Chandra, 2024). Studi yang fokus pada tanaman padi menunjukkan bahwa mekanisme self-attention dalam ViT bisa menangkap ciri-ciri lesi penyakit yang sangat kecil, yang sering kali terlewatkan saat proses pooling di arsitektur CNN [12]. Model ViT yang digunakan adalah jenis Klasifikasi yang ditawarkan oleh Roboflow, di mana teknik patch embedding diterapkan pada gambar masukan dengan ukuran 224×224 piksel. Pada tahap ini, seluruh dataset yang telah menjalani proses pra-pemrosesan (seperti pengubahan ukuran gambar menjadi 224×224 piksel, normalisasi, dan pembagian menjadi set pelatihan, set validasi, serta set pengujian) dimasukkan ke dalam model Vision Transformer untuk dilakukan proses klasifikasi.


Setiap token diproses melalui serangkaian lapisan Multi-Head Self Attention (MHSA) dan lapisan feed-forward untuk mengambil informasi spasial dari gambar daun padi. Hasil akhir dari proses ini kemudian dikirim ke classification head dengan fungsi aktivasi Softmax untuk memproduksi keluaran probabilitas dari sembilan jenis penyakit pada daun padi, yaitu: Bacterial Leaf Blight, Brown Spot, Healthy Rice Leaf, Leaf Blast, Leaf Scald, Narrow Brown Leaf Spot, Neck Blast, Rice Hispa, dan Sheath Blight.

Pelatihan dan validasi dilakukan secara otomatis oleh Roboflow dengan pengaturan pembagian data seperti yang dijelaskan dalam Tabel 2 (70% untuk set pelatihan, 20% untuk set validasi, dan 10% untuk set pengujian). Hasil dari pelatihan tersebut kemudian digunakan pada fase evaluasi model untuk mengevaluasi kemampuan dan tingkat akurasi klasifikasi yang dihasilkan oleh Vision Transformer.

D. Evaluasi Model

Evaluasi model bertujuan untuk menilai kinerja model Vision Transformer (ViT) dalam mengenali penyakit pada daun padi berdasarkan dataset yang tersedia. Model diuji dengan menggunakan data validasi yang tidak diikutsertakan dalam proses pelatihan, sehingga hasil evaluasi bisa mencerminkan seberapa baik model dalam melakukan generalisasi. Berdasarkan hasil tes, model berhasil mencapai akurasi 98.9%, yang menunjukkan bahwa model ini dapat mengidentifikasi kondisi daun padi dengan sangat tepat. Angka akurasi ini juga menunjukkan bahwa model mampu mengenali setiap jenis penyakit dengan konsisten.

Selain ketepatan, konsistensi kinerja model juga terlihat dari sesi pelatihan sebelumnya, di mana kerugian pelatihan berada pada angka rendah dan akurasi validasi tetap stabil. Ini mengindikasikan bahwa model tidak mengalami overfitting dan berfungsi secara optimal pada data baru. Gambar 3 di bawah ini memperlihatkan hasil penilaian model yang telah dilatih dengan metode Klasifikasi ViT.



Gambar 4 Hasil Model


IV. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan Model

Pembahasan mengenai hasil dari pelatihan disampaikan baik secara teoritis maupun kuantitatif dengan mengacu pada dua grafik utama, yaitu Training Loss dan Validation Accuracy. Ukuran-ukuran ini memberikan wawasan mengenai seberapa baik proses pembelajaran model serta kemampuannya dalam melakukan generalisasi. Hasil dari pelatihan digambarkan dalam format grafik untuk mempermudah pemahaman terhadap kinerja model di setiap epoch.

a) Training Loss


Training Loss berfungsi untuk mengukur seberapa besar kesalahan yang dilakukan model pada dataset latihan. Di awal epoch, nilai kehilangan berada di sekitar 0,46, yang menunjukkan bahwa model mulai beradaptasi dengan data. Dalam tiga epoch pertama, nilai kehilangan menurun dengan signifikan hingga di bawah 0,04. Setelah menyelesaikan epoch keempat, penurunan terjadi dengan lebih stabil dan konsisten hingga hampir mencapai 0,00 pada epoch yang ke-20. Pola ini mengindikasikan bahwa model berada dalam keadaan konvergen tanpa tanda-tanda underfitting maupun overfitting. Stabilitas penurunan ini menunjukkan bahwa pengaturan hyperparameter dan optimizernya telah berfungsi dengan baik.



Gambar 5 Grafik Pelatihan Training Loss

b) Validation Accuracy

Validation Accuracy menunjukkan sejauh mana model dapat menggeneralisasi terhadap data yang belum pernah dilihat sebelumnya. Di epoch pertama, akurasi validasi tercatat sekitar 0,92, yang merupakan awal yang menjanjikan untuk model pembelajaran mendalam. Akurasi terus meningkat dengan stabil pada epoch-epoch selanjutnya, dan berada dalam kisaran 0,96 hingga 0,99. Puncak akurasi diperoleh pada epoch ketujuh, yaitu 0,989. Dari epoch kesepuluh hingga kedua puluh, grafik akurasi menunjukkan kestabilan mendekati 0,98 hingga 0,99 tanpa adanya perubahan yang signifikan, yang membuktikan bahwa model tidak mengalami overfitting dan mampu mengenali pola visual dengan sangat baik.



Gambar 6 Grafik Pelatihan Validation Accuracy

Secara keseluruhan, grafik training loss dan validation accuracy memperlihatkan hasil pelatihan yang konsisten dan efisien. Penurunan kerugian yang berkelanjutan dan peningkatan akurasi validasi yang konstan menunjukkan bahwa model Vision Transformer dapat memahami ciri-ciri penyakit pada daun padi dengan baik, serta memiliki kemampuan generalisasi yang sangat memuaskan.


B. Hasil Validasi dan Evaluasi Model

Pengujian kemampuan model dilakukan dengan memanfaatkan fitur Custom Workflow di Roboflow untuk mengevaluasi efektivitas Vision Transformer (ViT) dalam mengidentifikasi penyakit pada daun padi dari citra yang tidak termasuk dalam data pelatihan. Proses ini meliputi langkah

unggah citra uji melalui modul input hingga menghasilkan prediksi, seperti yang dapat dilihat pada Gambar 7.

Pada tahap penilaian, model memproduksi label prediksi bersama nilai keyakinan dalam format JSON. Dari contoh hasil percobaan yang terdapat pada Gambar 7, model berhasil mendeteksi kelas "Rice Hispa" dengan tingkat kepercayaan yang tinggi, dan hasil prediksi tersebut ditampilkan secara langsung melalui modul Classification Label Visualization untuk mempermudah proses verifikasi.

Hasil evaluasi menunjukkan bahwa model ViT mampu memberikan hasil prediksi yang stabil dan tepat terhadap citra yang sebelumnya tidak dikenal. Kemampuan generalisasi ini terlihat dari konsistensi nilai keyakinan pada berbagai jenis citra uji. Selain itu, kecepatan inferensi yang dihasilkan menunjukkan bahwa model ini cocok digunakan dalam sistem deteksi penyakit daun padi secara real-time, baik untuk aplikasi pertanian presisi maupun penerapan di lapangan.



Gambar 7 Alur pengujian inferensi model ViT

C. Visualiasi Hasil Pelatihan

Untuk mengeksplorasi potensi peningkatan model, telah dilakukan perbandingan kinerja antara dua versi dari model Vision Transformer (ViT) yang telah dilatih: Model 1 yang memakai konfigurasi data dasar, dan Model 2 yang menerapkan teknik augmentasi data. Model kedua, Deteksi Penyakit Daun Padi 2, menambahkan augmentasi berupa pembalikan horizontal dan rotasi antara -45 derajat hingga +45 derajat. Penambahan augmentasi ini berhasil meningkatkan jumlah Train Set secara signifikan dari 8.154 menjadi 24.415 gambar

TABEL 3
PERBANDINGAN AKURASI KEDUA MODEL

Metrik	Model 1	Model 2
Akurasi	98,9%	99,4%
Status	Checkpoint sebelumnya	Fine-tuned terbaru (Terbaik)
Peningkatan	-	+0,5% dari Model 1

Seperti yang terlihat pada Tabel 3, dapat dilihat bahwa perbaikan data membawa peningkatan yang jelas dalam kinerja. Model yang dilatih dengan data yang ditingkatkan (Deteksi Penyakit Daun Padi 2) berhasil mencapai akurasi 99,4%, yang lebih tinggi dibandingkan akurasi Model 1 yang hanya 98,9%.

Kenaikan sebesar 0,5% ini menunjukkan bahwa metode augmentasi berhasil dalam menambah variasi spasial yang lebih beragam (seperti perubahan sudut pandang dan orientasi) dalam dataset pelatihan. Hal ini sejalan dengan hasil studi perbandingan lainnya yang menunjukkan bahwa model yang didasarkan pada Transformer memerlukan variasi data yang lebih banyak dibandingkan dengan CNN agar dapat mencapai konvergensi yang optimal, tetapi memberikan akurasi yang lebih unggul dalam jangka panjang [13]. Hal ini membuat Model 2 menjadi lebih tangguh dan lebih baik dalam

melakukan generalisasi ketika menghadapi gambar uji yang memiliki orientasi atau pencahayaan yang berbeda sedikit dari kondisi nyata. Dengan akurasi yang mencapai 99.4%, Model ViT yang mendapatkan augmentasi ini membuktikan kemampuannya sebagai solusi yang sangat dapat diandalkan untuk klasifikasi penyakit pada daun padi.

V.KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa Vision Transformer (ViT) efektif dalam mengklasifikasikan penyakit daun padi, dengan akurasi pengujian mencapai 99,4% setelah augmentasi data. Model ini dapat mengekstrak fitur lokal dan global, memungkinkan deteksi variasi gejala penyakit yang halus dengan konsistensi tinggi di seluruh kelas. Keunggulan ViT dibandingkan CNN yang biasa digunakan terletak pada mekanisme perhatian diri yang menangkap konteks secara keseluruhan dan hubungan jarak jauh antar bagian citra, sehingga memungkinkan identifikasi pola penyakit yang rumit. Namun, model ini membutuhkan dataset yang cukup besar dan waktu pelatihan yang lebih lama untuk mencapai performa terbaik. Untuk penelitian selanjutnya, disarankan untuk memperluas dataset dengan citra lapangan secara real-time, mengintegrasikan sistem dengan perangkat IoT untuk deteksi penyakit secara langsung, serta mengeksplorasi kombinasi ViT dengan teknik augmentasi atau transfer learning untuk meningkatkan efisiensi dan akurasi model.

UCAPAN TERIMA KASIH

Para penulis ingin menyampaikan penghargaan yang tulus kepada semua pihak yang telah mendukung pelaksanaan penelitian ini. Ucapan terima kasih khusus disampaikan kepada Politeknik Negeri Subang yang telah menyediakan lingkungan akademis dan fasilitas yang memungkinkan selesainya jurnal ini.

Penulis juga mengungkapkan rasa terima kasih yang mendalam kepada dosen pembimbing yang telah memberikan arahan, wawasan berharga, dan dorongan yang berkelanjutan selama proses penelitian. Keahlian dan masukan konstruktif mereka sangat penting dalam meningkatkan kualitas karya ini. Selanjutnya, para penulis mengucapkan terima kasih kepada pihak-pihak yang telah menyumbangkan dataset penyakit daun padi yang tersedia untuk umum di platform Roboflow dan Kaggle, yang memainkan peran penting dalam pengembangan dan evaluasi model yang diusulkan. Terakhir, rasa terima kasih yang tulus disampaikan kepada rekan-rekan dan penilai yang masukan konstruktifnya sangat meningkatkan naskah akhir.

DAFTAR PUSTAKA

- [1] C. G. Simhadri and H. K. Kondaveeti, "Automatic Recognition of Rice Leaf Diseases Using Transfer Learning," *Agronomy*, vol. 13, no. 4, Apr. 2023, doi: 10.3390/agronomy13040961.
- [2] P. Pai *et al.*, "Deep learning-based automatic diagnosis of rice leaf diseases using ensemble CNN models," *Sci Rep*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-13079-z.
- [3] S. Mehnaz and Md. T. Islam, "Rice Leaf Disease Detection: A Comparative Study Between CNN, Transformer and Non-neural Network Architectures," Jan. 2025, [Online]. Available: <http://arxiv.org/abs/2501.06740>
- [4] J. Zhao *et al.*, "A review of plant leaf disease identification by deep learning algorithms," 2025, *Frontiers Media SA*. doi: 10.3389/fpls.2025.1637241.
- [5] Yazid Fauzan Nur Ashfani, Yovi Litanianda, and Rizqy Amalia Putri, "Klasifikasi Jenis Buah Jeruk Menggunakan Metode Convolutional Neural Network: Deep Learning Studi," *Uranus : Jurnal Ilmiah Teknik Elektro, Sains dan Informatika*, vol. 2, no. 2, pp. 70–79, Jun. 2024, doi: 10.61132/uranus.v2i2.129.
- [6] D. E. Saputra *et al.*, "Implementasi Deep Learning Untuk Identifikasi Penyakit Melalui Daun Pada Tanaman Padi Menggunakan Metode Convolutional Neural Network."
- [7] Atika Apriani, Kusworo Adi, and Catur Edi Widodo, "CNN-Based Identification of Rice Leaf Diseases," *Int J Sci Res Sci Technol*, vol. 12, no. 3, pp. 1204–1211, Jun. 2025, doi: 10.32628/ijrst25123120.
- [8] A. Dosovitskiy *et al.*, "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," Jun. 2021, [Online]. Available: <http://arxiv.org/abs/2010.11929>
- [9] D. A. Pusparani, M. W. A. Kesiman, and K. Y. E. Aryanto, "Identification of Little Tuna Species Using Convolutional Neural Networks (CNN) Method and ResNet-50 Architecture," *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 8, no. 1, p. 86, Dec. 2024, doi: 10.24014/ijaidm.v8i1.31620.
- [10] Supiyandi Supiyandi, Mona Donaon, and Muhammad Yusuf Azmi, "Analisis Sistem Aplikasi Pengolahan Citra Pada Pertanian Cerdas Untuk Pemantauan Tanaman," *SABER : Jurnal Teknik Informatika, Sains dan Ilmu Komunikasi*, vol. 2, no. 3, pp. 221–228, Jul. 2024, doi: 10.59841/saber.v2i3.1443.
- [11] E. Olaniyi, D. Chen, Y. Lu, and Y. Huang, "Generative Adversarial Networks for Image Augmentation in Agriculture: A Systematic Review," Apr. 2022, [Online]. Available: <http://arxiv.org/abs/2204.04707>
- [12] R. K. Rachman, D. R. I. M. Setiadi, A. Susanto, K. Nugroho, and H. M. M. Islam, "Enhanced Vision Transformer and Transfer Learning Approach to Improve Rice Disease Recognition," *Journal of Computing Theories and Applications*, vol. 1, no. 4, pp. 446–460, Apr. 2024, doi: 10.62411/jcta.10459.
- [13] D. A. Allan Bil Faqih, "05-1440-Identifikasi+Penyakit+Daun+pada+Tanaman+Solana ceae+dan+Rosaceae+Menggunakan+Deep+Learning," *Jurnal Teknologi Terpadu*, vol. 10, pp. 105–116, 2024.