

# Klasifikasi Penyakit Daun Cabai Menggunakan Vision Transformer

Fitrandi Ramadhana<sup>1</sup>, Gayuh Abdi Mahardika<sup>2</sup>, Nakata Day<sup>3</sup>, Eva Yulia Puspaningrum<sup>4\*</sup>

<sup>1,2,3</sup> Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur

<sup>1</sup>22081010005@student.upnjatim.ac.id

<sup>2</sup>22081010067@student.upnjatim.ac.id

<sup>3</sup>22081010228@student.upnjatim.ac.id

<sup>4</sup>evapuspaningrum.if@upnjatim.ac.id

<sup>4</sup> Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

\*Corresponding author email: [evapuspaningrum.if@upnjatim.ac.id](mailto:evapuspaningrum.if@upnjatim.ac.id)

**Abstrak**— Deteksi dini penyakit daun cabai merupakan langkah penting dalam menjaga produktivitas pertanian dan mendukung ketahanan pangan, mengingat potensi kerugian hasil panen yang besar akibat infeksi. Metode konvensional seringkali bersifat subjektif, memakan waktu, dan tidak efektif untuk pengawasan dalam skala besar. Convolutional Neural Networks (CNN) telah banyak digunakan dalam tugas klasifikasi penyakit tanaman, namun memiliki keterbatasan dalam menangkap dependensi spasial jarak jauh dan kemampuan generalisasi pada kondisi lingkungan yang bervariasi. Penelitian ini mengusulkan penerapan Vision Transformer (ViT) sebagai pendekatan alternatif untuk klasifikasi penyakit daun cabai. ViT memanfaatkan mekanisme self-attention yang memungkinkan pemodelan informasi global secara lebih efektif dibandingkan CNN. Dalam penelitian ini, ViT digunakan untuk mengklasifikasikan beberapa jenis penyakit daun cabai seperti leaf curl, leaf spot, whitefly, dan yellowish. Hasil eksperimen menunjukkan bahwa ViT mampu memberikan akurasi tinggi, dengan persentase presisi mencapai 95,97%, dan performa yang stabil dalam mendeteksi berbagai jenis penyakit, menjadikannya solusi yang menjanjikan untuk mendukung sistem pertanian presisi dan mengurangi kerugian akibat penyakit tanaman.

**Kata Kunci:** Penyakit daun cabai, klasifikasi citra, Vision Transformer.

Namun, metode ini memiliki keterbatasan seperti ketergantungan pada pengalaman individu, tingkat subjektivitas yang tinggi, waktu yang lama, serta kesulitan dalam mendeteksi gejala pada tahap awal [2]. Seiring dengan berkembangnya teknologi *Machine Learning* (ML) dan *Computer Vision*, pendekatan otomatis untuk mendeteksi penyakit tanaman menjadi solusi yang potensial. CNN telah banyak digunakan dalam klasifikasi citra, namun memiliki keterbatasan dalam menangkap hubungan spasial jarak jauh dan mengalami penurunan performa pada kondisi citra kompleks [4].

*Vision Transformer* (ViT) hadir sebagai solusi alternatif dengan mengadaptasi arsitektur Transformer dari NLP ke domain visi komputer. ViT menggunakan mekanisme self-attention yang unggul dalam memahami pola visual global dan kompleks [1]. Penelitian ini bertujuan untuk mengimplementasikan ViT dalam klasifikasi penyakit daun cabai, mencakup lima kelas yaitu *healthy*, *leaf curl*, *leaf spot*, *whitefly*, dan *yellowish*. Diharapkan model ini dapat memberikan hasil klasifikasi yang akurat dan berkontribusi terhadap sistem deteksi otomatis dalam pertanian presisi.

## I. PENDAHULUAN

Penyakit tanaman merupakan tantangan besar bagi pertanian global karena dapat menurunkan hasil panen secara signifikan, mengancam ketahanan pangan, dan berdampak negatif terhadap kesejahteraan ekonomi petani [1]. Deteksi penyakit yang cepat dan akurat menjadi hal krusial dalam upaya mitigasi dampak tersebut melalui manajemen penyakit yang efektif. Tanaman cabai, sebagai salah satu komoditas hortikultura bernilai ekonomi tinggi dan kaya akan kandungan gizi, rentan terhadap berbagai jenis penyakit daun [3]. Jika tidak dikenali dan ditangani sejak dini, penyakit-penyakit tersebut dapat menyebabkan kerugian hasil panen yang substansial. Identifikasi penyakit pada tanaman secara tradisional dilakukan melalui inspeksi visual oleh para ahli.

## II. METODOLOGI

### A. Penyakit Daun Cabai

Penyakit daun cabai yang umum ditemukan antara lain *leaf curl* (keriting daun), *leaf spot* (bercak), *whitefly* (infeksi akibat serangga kutu putih), *yellowish* (menguning akibat stres atau virus), serta kondisi sehat (*healthy*). Deteksi dini penyakit-penyakit ini penting untuk menjaga kualitas dan kuantitas produksi.

### B. Vision Transformer (ViT)

ViT adalah model *deep learning* yang mengadaptasi arsitektur Transformer dari NLP ke klasifikasi citra. Dibandingkan

CNN, ViT menggunakan *self-attention* untuk memahami informasi spasial secara global, sehingga lebih baik dalam mengenali pola kompleks dan hubungan jarak jauh dalam citra. Menurut Dosovitskiy et al. [1], ViT memiliki keunggulan dalam klasifikasi gambar ketika dilatih dengan data dalam jumlah besar dan ukuran input gambar yang sesuai.

### C. Alur

Implementasi Vision Transformer (ViT) dalam penelitian ini mengikuti metodologi yang terstruktur dan komprehensif. Diawali dengan tahap persiapan dataset yang meliputi pengumpulan, pengorganisasian, dan pembagian data menjadi set pelatihan, validasi, dan pengujian. Pada tahap ini juga diterapkan berbagai teknik augmentasi data seperti rotasi, flipping, dan perubahan brightness/contrast untuk meningkatkan variasi dan keragaman data pelatihan.

Selanjutnya, dilakukan pra-pemrosesan data dengan melakukan resizing gambar ke dimensi yang seragam sesuai kebutuhan input ViT, normalisasi nilai piksel, serta pembagian gambar menjadi patch-patch berukuran tetap yang akan menjadi unit dasar untuk pemrosesan transformer. Pendekatan ini sangat krusial karena berbeda dengan CNN yang memproses gambar secara langsung, ViT memerlukan transformasi gambar menjadi sekuens *patch*.

Arsitektur *Vision Transformer* diimplementasikan dengan menerapkan *patch embedding* untuk mengkonversi patch gambar menjadi representasi token, dilengkapi dengan penambahan token klasifikasi [CLS] dan embedding posisi untuk mempertahankan informasi spasial. Model ini terdiri dari beberapa *layer transformer encoder* dengan mekanisme multi-head *self-attention* yang menjadi kekuatan utama dalam menangkap hubungan jarak jauh antar elemen visual, diakhiri dengan MLP head untuk tugas klasifikasi spesifik.

Proses pelatihan model dilaksanakan dengan inisialisasi model (baik dari awal maupun menggunakan *pre-trained weights*), konfigurasi hyperparameter seperti *learning rate*, *batch size*, dan jumlah epoch, serta implementasi strategi optimisasi dan penjadwalan learning rate yang sesuai. Selama pelatihan, performa model terus dipantau pada set validasi untuk mencegah terjadinya overfitting dan memastikan generalisasi model yang optimal.

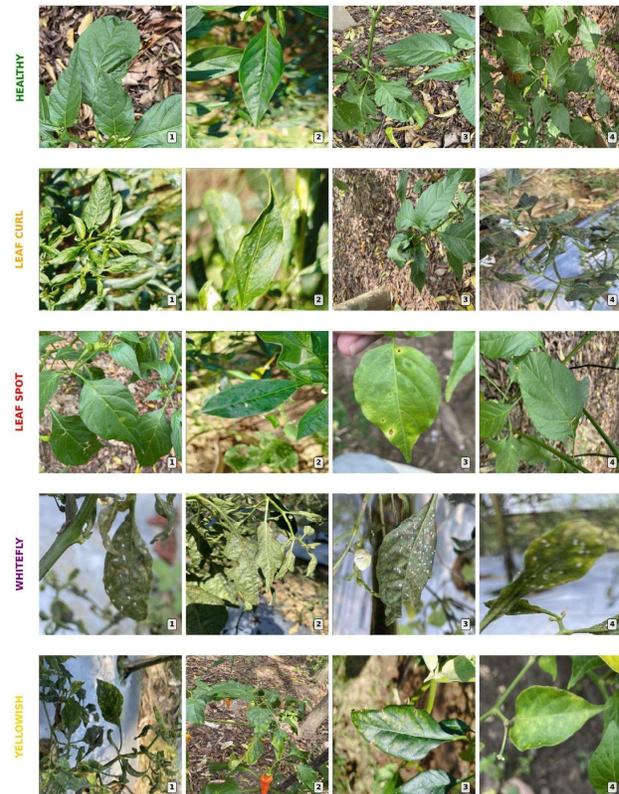
Evaluasi komprehensif dilakukan dengan mengukur berbagai metrik performa seperti akurasi, precision, recall, dan F1-score pada set pengujian independen. Analisis confusion matrix digunakan untuk memahami pola kesalahan klasifikasi, sementara visualisasi attention map membantu meningkatkan interpretabilitas model dengan menunjukkan bagian gambar yang menjadi fokus perhatian model dalam pengambilan keputusan.

Metodologi diakhiri dengan proses fine-tuning dan optimisasi melalui eksperimen berbagai konfigurasi hyperparameter, penerapan teknik regularisasi seperti dropout dan weight decay, serta optimisasi model untuk meningkatkan efisiensi komputasi tanpa mengorbankan akurasi. Pendekatan metodologis ini dirancang untuk memaksimalkan keunggulan ViT dalam memproses informasi visual secara global melalui mekanisme attention, sekaligus mengatasi tantangan komputasi dan kebutuhan data yang besar pada arsitektur transformer. Pendekatan augmentasi yang komprehensif ini sangat penting untuk melatih model yang mampu berkinerja baik pada kondisi citra yang natural dan kompleks

### Dataset

Dataset yang digunakan terdiri dari lima kelas, yaitu *healthy*, *leaf curl*, *leaf spot*, *whitefly*, dan *yellowish*. Seluruh data dikumpulkan dari sumber daring yang telah diverifikasi. Total citra real yang digunakan dalam penelitian ini adalah sebanyak 1.445 gambar dengan ukuran 512 x 512, yang dibagi ke dalam *folder train*, *validation*, dan tes secara proporsional agar proses pelatihan dan evaluasi dapat berjalan optimal. Masing-masing kelas memiliki jumlah data yang relatif seimbang untuk mencegah ketimpangan distribusi yang dapat mempengaruhi performa model.

Chili Leaf Disease Dataset - Sample Images



Gbr. 1. dataset daun cabai

### D. Preprocessing

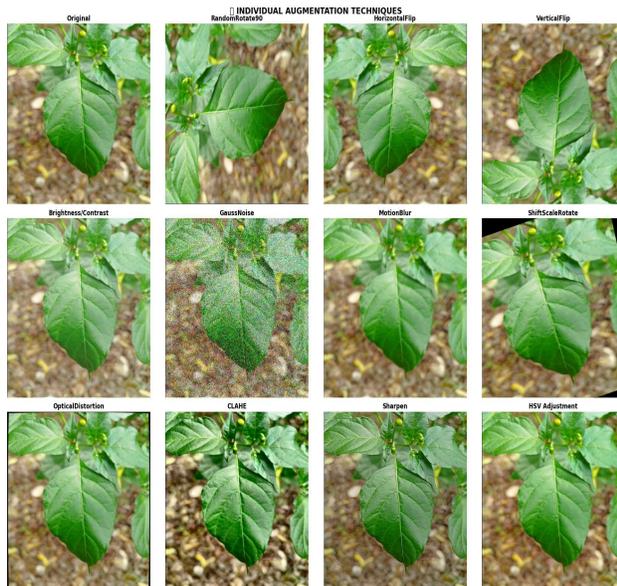
Seluruh citra pada dataset diubah ukurannya menjadi 224x224 piksel. Penyesuaian resolusi ini dilakukan agar sesuai dengan arsitektur model ViT yang digunakan, yaitu ViT-Base Patch16-224. Ukuran 224x224 merupakan standar input yang digunakan pada ViT pre-trained yang dilatih di atas dataset ImageNet, sebagaimana dijelaskan oleh Dosovitskiy et al. [1], di mana pemrosesan gambar dibagi menjadi patch berukuran 16x16 piksel pada citra 224x224 untuk memastikan Kompatibilitas dengan struktur patch embedding. Selain itu, ukuran ini memberikan efisiensi memori dan waktu peralihan tanpa mengorbankan kualitas informasi visual. Untuk meningkatkan kemampuan generalisasi model terhadap data dilapangan, dilakukan augmentasi data secara ekstensif menggunakan pustaka *albumentations*. Teknik augmentasi yang diterapkan mencakup rotasi acak sebesar 90 derajat, pembalikan horizontal dan vertikal, penyesuaian brightness dan kontras, penambahan noise Gaussian, serta beberapa transformasi lanjutan seperti motion blur, *optical distortion*, *emboss*, *sharpen*, dan manipulasi *hue-saturation*.

Berdasarkan pengolahan data, total citra hasil augmentasi yang dihasilkan adalah sebanyak 2.890 gambar, sehingga dataset pelatihan akhir terdiri dari 4.335 gambar. Rincian distribusi data hasil augmentasi untuk setiap kelas adalah sebagai berikut: kelas healthy sebanyak 578 gambar, leaf curl sebanyak 577 gambar, leaf spot sebanyak 578 gambar, whitefly sebanyak 578 gambar, dan yellowish sebanyak 579 gambar. Pendekatan augmentasi ini disesuaikan dengan praktik terbaik yang umum digunakan dalam pelatihan model klasifikasi tanaman pada kondisi citra natural dan kompleks seperti dijelaskan oleh Mohanty et al. [2].

#### E. Skenario Uji Coba

Skenario uji coba dilakukan menggunakan satu pendekatan utama, yakni pelatihan model ViT menggunakan seluruh data real dan hasil augmentasi sebanyak 4.335 gambar yang telah dibagi ke dalam data latih, validasi, dan uji. Pengujian dilakukan dengan mengevaluasi performa model berdasarkan metrik akurasi, precision, recall, F1-score, dan confusion matrix terhadap data uji. Pendekatan ini bertujuan untuk menilai kemampuan ViT dalam mendeteksi penyakit daun cabai berdasarkan data nyata dan representatif.

Dalam penelitian ini, augmentasi data dilakukan secara agresif menggunakan pipeline yang dirancang untuk meningkatkan variasi dan jumlah data pelatihan secara signifikan. Setiap gambar dari dataset asli melewati serangkaian augmentasi probabilistik seperti tampak pada Gbr. 2. Transformasi affine dasar meliputi Random Rotate 90 ( $p=0.5$ ), Flip ( $p=0.5$ ), dan Shift Scale Rotate ( $p=0.2$ ). Untuk simulasi variasi pencahayaan dan warna, pipeline menerapkan Random Brightness Contrast ( $p=0.5$ ) dan Hue Saturation Value ( $p=0.3$ ). Guna meningkatkan robustisitas model terhadap artefak gambar, pipeline juga menyertakan Gauss Noise ( $p=0.3$ ) dan salah satu dari Motion Blur, Median Blur, atau Blur ( $p=0.2$ ). Lebih lanjut, untuk mensimulasikan distorsi geometris yang kompleks, diterapkan salah satu dari Optical Distortion, Grid Distortion, atau Piecewise Affine ( $p=0.2$ ). Terakhir, untuk mengubah karakteristik kualitas gambar, salah satu dari CLAHE, Sharpen, Emboss, atau Random Gamma diaplikasikan dengan probabilitas 30%.



Gbr. 2. preprocessing daun cabai

## HASIL DAN PEMBAHASAN

### A. Evaluasi Kinerja Model

Proses pelatihan model diatur dengan konfigurasi hyperparameter yang telah ditentukan untuk tugas klasifikasi ini. Pelatihan dijalankan selama 20 epoch untuk memastikan konvergensi model yang memadai. Dalam setiap iterasinya, data diproses menggunakan ukuran batch sebesar 32. Untuk mengoptimalkan pembaruan bobot model, *optimizer* dikonfigurasi dengan tingkat pembelajaran (learning rate) awal sebesar 0.0003. Pengaturan ini dipilih untuk menyeimbangkan antara kecepatan belajar dan stabilitas selama proses *fine-tuning*.

Seperti tampak pada tabel 1, pada fase awal (epoch 1-4), model menunjukkan konvergensi yang cepat, ditandai dengan penurunan signifikan pada *validation loss* dari 0.3421 menjadi 0.1597 dan peningkatan akurasi validasi hingga 94.35%. Hal ini mengindikasikan keberhasilan proses *transfer learning* dari bobot pra-terlatih. Kinerja model kemudian memasuki fase stabilisasi dengan beberapa fluktuasi, seperti anomali pada epoch ke-8 di mana terjadi lonjakan *validation loss* (0.4539) dan penurunan akurasi sesaat, yang kemungkinan disebabkan oleh komposisi stokastik dari *validation batch*. Namun, model menunjukkan robustisitas dengan cepat kembali ke performa tinggi. Dari epoch ke-10 hingga ke-18, model berada pada performa plateau di sekitar akurasi 95.16% sambil terus meminimalkan *training loss*. Pada dua epoch terakhir (19-20), model berhasil mencapai titik konvergensi optimum yang baru, dengan akurasi validasi puncak sebesar 95.97%.

Kesenjangan (gap) yang terjaga antara *training loss* dan *validation loss* sepanjang pelatihan mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* yang signifikan.

TABEL 1. HASIL TRAINING

Epoch	Train Loss	Validation Loss	Validation Accuracy (%)	Learning Rate
1	0.9743	0.3421	87.90	2.98e-04
2	0.5603	0.2807	91.94	2.93e-04
3	0.4345	0.2689	91.94	2.84e-04
4	0.3920	0.1597	94.35	2.71e-04
5	0.3298	0.2835	91.13	2.56e-04
6	0.3138	0.1321	95.16	2.38e-04
7	0.2759	0.1864	93.55	2.18e-04
8	0.2846	0.4539	85.48	1.97e-04
9	0.2933	0.1891	94.35	1.74e-04
10	0.2479	0.1670	95.16	1.50e-04
11	0.2294	0.1640	95.16	1.27e-04
12	0.2086	0.1618	95.16	1.04e-04
13	0.1812	0.1390	95.16	8.26e-05
14	0.1672	0.1949	95.16	6.26e-05
15	0.1692	0.1554	94.35	4.48e-05
16	0.1347	0.1460	94.35	2.96e-05
17	0.1127	0.1494	95.16	1.73e-05
18	0.1344	0.1533	95.16	8.32e-06
19	0.1157	0.1468	95.97	2.84e-06
20	0.1135	0.1375	95.97	2.75e-06

### B. Analisis Hasil

Setelah menyelesaikan 20 epoch pelatihan dan mencapai akurasi validasi puncak sebesar 95.97%, performa akhir model diuji secara komprehensif pada *test set*. Data uji ini terdiri dari 62 gambar yang sepenuhnya baru dan belum pernah digunakan dalam proses pelatihan maupun validasi. Tahap ini krusial untuk mengukur kemampuan generalisasi model, yaitu kemampuannya untuk bekerja secara akurat pada data dunia nyata.

TABEL 2. HASIL KLASIFIKASI

Class	Precision	Recall	F1-Score	Jumlah Sampel
Healthy	0.92	0.92	0.92	12
Leaf Curl	0.92	1.00	0.96	11
Leaf Spot	0.91	0.83	0.87	12
Whitefly	0.93	1.00	0.96	13
Yellowish	1.00	0.93	0.96	14
Accuary			0.94	62
Macro Avg	0.93	0.94	0.93	62
Weighted Avg	0.94	0.94	0.93	62

Hasil pengujian pada data uji menghasilkan akurasi keseluruhan sebesar 93.55% bisa dilihat di tabel 3. Angka ini, meskipun sedikit di bawah akurasi validasi puncak, merupakan indikator yang sangat kuat bahwa model memiliki kemampuan generalisasi yang robust. Penurunan minor antara akurasi validasi dan tes adalah hal yang wajar dan menunjukkan bahwa model tidak mengalami *overfitting* secara signifikan. Metrik weighted avg untuk F1-score sebesar 0.93 lebih lanjut mengkonfirmasi kinerja yang seimbang dan andal di seluruh kelas, dengan mempertimbangkan jumlah sampel di masing-masing kelas.

TABEL 3. KLASIFIKASI CLASS

Class	Akurasi
Healthy	91.67%
Leaf Curl	100.00%
Leaf Spot	83.33%
Whitefly	100.00%
Yellowish	92.86%

Model menunjukkan kinerja yang luar biasa pada beberapa kelas. Untuk kelas Leaf Curl dan Whitefly, model mencapai nilai recall 1.00 (100%). Metrik ini sangat vital dalam konteks diagnosis penyakit, karena ini berarti model berhasil mengidentifikasi semua sampel yang benar-benar terinfeksi penyakit tersebut tanpa ada yang terlewat (tidak ada *false negative*). Selain itu, kelas Yellowish mencatatkan precision 1.00, yang berarti setiap kali model memprediksi sebuah daun sebagai "Yellowish", prediksi tersebut 100% benar (tidak ada *false positive*). Tingkat presisi dan recall yang sangat tinggi pada kelas-kelas ini menunjukkan bahwa fitur visual yang dipelajari oleh model sangat diskriminatif dan efektif.

Kelas Leaf Spot tercatat sebagai kelas yang paling menantang bagi model. Hal ini tercermin dari nilai recall terendah sebesar 0.83 (83.33%) dan F1-score 0.87. Nilai recall yang lebih rendah ini mengindikasikan bahwa model gagal mengidentifikasi sekitar 17% dari total kasus Leaf Spot yang sebenarnya, dan keliru mengklasifikasikannya sebagai kelas

lain. Kemungkinan, hal ini disebabkan oleh karakteristik visual dari "bercak daun" yang bisa jadi sangat bervariasi, berukuran kecil, atau memiliki kemiripan dengan kerusakan fisik ringan atau tahap awal penyakit lain, sehingga menjadi lebih ambigu bagi model. Meskipun demikian, nilai *precision* untuk Leaf Spot masih tergolong tinggi (0.91), yang menunjukkan bahwa ketika model sudah berhasil membuat prediksi "Leaf Spot", prediksi tersebut memiliki tingkat kepercayaan yang baik.

Secara keseluruhan, hasil evaluasi pada data uji memvalidasi efektivitas arsitektur Vision Transformer untuk tugas ini. Kemampuan model untuk mencapai akurasi di atas 93% pada data yang belum pernah dilihat sebelumnya, dengan performa nyaris sempurna pada beberapa kategori penyakit, menegaskan potensinya sebagai alat bantu diagnostik yang andal. Tantangan yang ada pada kelas Leaf Spot memberikan wawasan berharga untuk pengembangan di masa depan, misalnya dengan menambahkan lebih banyak sampel data yang bervariasi untuk kelas tersebut guna meningkatkan sensitivitas model.

### III. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa arsitektur *Vision Transformer* (ViT) merupakan solusi yang sangat efektif dan andal untuk tugas klasifikasi penyakit pada daun cabai secara otomatis. Dengan memanfaatkan pendekatan *transfer learning* pada model ViT-Base yang telah dilatih sebelumnya dan diperkuat dengan teknik augmentasi data yang ekstensif, model yang dikembangkan mampu mempelajari fitur-fitur visual yang kompleks dan relevan untuk membedakan antara daun sehat dan empat jenis penyakit yang berbeda.

Proses pelatihan yang sistematis selama 20 epoch menunjukkan konvergensi yang baik, di mana model berhasil mencapai akurasi validasi puncak sebesar 95.97%. Kinerja model ini kemudian diuji pada set data yang sepenuhnya baru dan tidak terlihat sebelumnya, di mana ia berhasil memperoleh akurasi keseluruhan yang tinggi sebesar 93.55%. Hasil ini mengkonfirmasi kemampuan generalisasi model yang kuat dan kemampuannya untuk beroperasi secara efektif di luar data pelatihan.

Analisis kinerja per kelas menunjukkan kekuatan model dalam mengidentifikasi beberapa penyakit secara spesifik. Model mencapai recall 100% untuk kelas *Leaf Curl* dan *Whitefly*, yang berarti tidak ada kasus penyakit tersebut yang terlewatkan. Meskipun menghadapi tantangan yang sedikit lebih besar pada kelas *Leaf Spot* dengan recall 83.33%, secara keseluruhan model menunjukkan presisi dan F1-score yang tinggi di semua kategori, dengan rata-rata makro F1-score 0.93.

Secara keseluruhan, penelitian ini memvalidasi bahwa ViT, dengan mekanisme *self-attention* yang mampu menangkap informasi global, menawarkan alternatif yang kuat dan bahkan lebih unggul dibandingkan pendekatan konvensional untuk deteksi penyakit tanaman. Implementasi teknologi ini memiliki potensi besar untuk diaplikasikan dalam sistem pertanian presisi, membantu petani melakukan deteksi dini secara cepat dan akurat, sehingga dapat mengurangi kerugian panen dan mendukung ketahanan pangan.

### IV. REFERENSI

- [1] A. Dosovitskiy *et al.*, "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," *arXiv:2010.11929*, 2020.
- [2] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using Deep Learning for

- Image-Based Plant Disease Detection,” *Frontiers in Plant Science*, 2016.
- [3] S. Khan *et al.*, “Transformers in Vision: A Survey,” *ACM Computing Surveys*, 2022.
- [4] C. Tan *et al.*, “A Survey on Deep Transfer Learning,” in *ICANN*, 2018.
- [5] K. He *et al.*, “Deep Residual Learning for Image Recognition,” in *CVPR*, 2016.
- [6] F. L. Gaol, “Analisis Kinerja Hyperparameter Convolutional,” *208160010 - Fulltext*, n.d.
- [7] I. Sanjaya, T. Lelita, and I. Yustiana, “Application of Vision Transformer for Identifying Indonesian Herbal Plants Based on Visual Images,” *Jurnal Media Informatika Budidarma*, vol. 4, no. 2, n.d., doi: <https://doi.org/10.37676/jmcs.v4i2>.
- [8] A. Asrafil *et al.*, “Klasifikasi Penyakit Tanaman Apel dari Citra Daun dengan Convolutional Neural Network,” n.d.
- [9] A. J. Bastari and A. Cherid, “Klasifikasi Penyakit Tanaman Tomat Menggunakan Convolutional Neural Network dan Implementasi Model H5 pada Aplikasi Desktop,” *SIMKOM*, vol. 8, no. 2, pp. 199–207, 2023, doi: <https://doi.org/10.51717/simkom.v8i2.194>
- [10] H. Cipta Di Lindungi Undang-Undang, “Program Studi Informatika Fakultas Teknik Universitas Medan Area,” 2024.
- [11] E. Nahak, R. P. Putra, and F. Marisa, “Klasifikasi Penyakit pada Tanaman Apel Melalui Citra Daun Menggunakan Metode Multiclass Support Vector Machine,” vol. 11, no. 3, pp. 401–408, 2024. [Online]. Available: <http://jurnal.mdp.ac.id>
- [12] H. Nurdiana, N. Lestari, and A. Sobri, “Klasifikasi Penyakit Tanaman Padi Berdasarkan Kondisi Daun Menggunakan Compact Convolutional Transformers,” vol. 14, no. 1, 2025, doi: <https://doi.org/10.34010/komputa.v14i1>.
- [13] A. Putra, “Klasifikasi Penyakit Daun Cabai Dengan Metode CNN untuk Deteksi Awal,” *Jurnal Profesi Insinyur Universitas Lampung*, vol. 6, no. 1, 2025, doi: <https://doi.org/10.23960/jpi.v6n1.147>.
- [14] R. H. Putra, H. M. Ridwan, I. Abiansyah, and T. Agustin, “Klasifikasi Daun Tomat Sehat dan Terserang Penyakit Menggunakan Metode Convolutional Neural Network (CNN),” *Seminar Nasional AMIKOM Surakarta (SEMNAS)*, 2024. [Online]. Available: <https://www.kaggle.com/datasets/kaustubhb999/tomatoleaf>
- [15] A. Setiawan *et al.*, “Klasifikasi Penyakit Tanaman Mangga Menggunakan Algoritma CNN pada Citra Daun,” in *Mekatronika dan Ilmu Komputer*, Universitas Nusa Putra, 2022.
- [16] M. Setiono, “Klasifikasi Penyakit Antraknosa Citra Cabai Rawit dengan Metode Convolutional Neural Network (CNN),” vol. 11, no. 2, 2024.