

ANALISIS PENGARUH VARIASI EPOCH PELATIHAN TERHADAP KINERJA MODEL MOBILENETV2 DALAM KLASIFIKASI PENYAKIT DAUN APEL

^{1*}Mochamad Hafid, ²Wahyu Cahyo Utomo, ³Danang Wahyu Widodo

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹hafideft1@gmail.com, ²wahyu.utomo@unpkdr.ac.id,

³danangwahyuwidodo@unpkediri.ac.id

Penulis Korespondens : Mochamad Hafid

Abstrak— Tanaman apel merupakan komoditas hortikultura bernilai ekonomi tinggi yang produktivitasnya bergantung pada kesehatan daun. Proses identifikasi penyakit secara manual oleh petani memiliki kelemahan berupa subjektivitas tinggi, memakan waktu lama, dan rentan salah diagnosis. Penelitian ini bertujuan menganalisis pengaruh variasi jumlah epoch pelatihan terhadap kinerja model *deep learning* MobileNetV2 dalam klasifikasi penyakit daun apel pada antarmuka web sederhana. Metode yang digunakan adalah *Development Research* dengan model sekuensial Waterfall. Dataset berjumlah 18.178 citra gabungan dari Plant Pathology 2021 FGVC8 dan data lapangan dengan rasio pembagian 70:15:15. Eksperimen dilakukan dengan memvariasikan jumlah epoch pelatihan dalam tiga fase bertahap guna menentukan konfigurasi optimal yang menghasilkan akurasi tertinggi sekaligus meminimalkan risiko overfitting. Hasil eksperimen menunjukkan model dengan konfigurasi epoch optimal mencapai akurasi 0.9025 (tanpa TTA) dan 0.9182 (dengan TTA 20 varian, F1-Macro 0.9277) dan berhasil diimplementasikan pada antarmuka web sederhana sebagai media demonstrasi klasifikasi penyakit daun apel secara langsung.

Kata Kunci— Deep Learning, Epoch, Klasifikasi Penyakit Daun, MobileNetV2

Abstract— Apple plants are a high economic value horticultural commodity whose productivity depends on leaf health. The manual disease identification process by farmers has weaknesses such as high subjectivity, being time-consuming, and prone to misdiagnosis. This study aims to analyze the effect of varying the number of training epochs on the performance of the MobileNetV2 deep learning model in apple leaf disease classification. The method used is Development Research with the sequential Waterfall model. The dataset consists of 18,178 images combined from Plant Pathology 2021 FGVC8 and field data with a 70:15:15 splitting ratio. Experiments were conducted by varying training epochs across three progressive phases to determine the optimal configuration that yields the highest accuracy while minimizing the risk of overfitting. The results show that the model with the optimal epoch configuration achieves an accuracy of 0.9025 (without TTA) and 0.9182 (with TTA using 20 variants, F1-Macro 0.9277) and was successfully deployed on a simple web interface as a demonstration platform for apple leaf disease classification.

Keywords— Deep Learning, Epoch, Leaf Disease Classification, MobileNetV2,

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Tanaman apel merupakan komoditas hortikultura bernilai ekonomi tinggi yang banyak dibudidayakan di wilayah beriklim sedang. Produktivitas tanaman ini sangat bergantung pada kesehatan daunnya karena peran vitalnya dalam proses fotosintesis yang menentukan pertumbuhan dan kualitas buah. Namun, berbagai jenis penyakit seperti Apple Scab, Cedar Rust, Frogeye Leaf Spot, dan Powdery Mildew menjadi ancaman utama yang dapat menurunkan hasil panen serta kualitas buah secara signifikan, sehingga menimbulkan kerugian ekonomi besar bagi petani [1]. Permasalahan utama di lapangan adalah proses identifikasi penyakit daun yang masih dilakukan secara manual berdasarkan perkiraan visual petani. Metode manual ini membutuhkan waktu lama, bersifat subjektif, dan rentan terhadap kesalahan, terutama bagi petani pemula yang belum berpengalaman.

Seiring perkembangan teknologi kecerdasan buatan, pendekatan *deep learning* berbasis Convolutional Neural Network (CNN) membuka peluang besar untuk melakukan deteksi otomatis penyakit tanaman secara cepat dan presisi. Salah satu aspek kritis dalam pelatihan model *deep learning* adalah penentuan jumlah epoch yang tepat. Epoch yang terlalu sedikit menyebabkan *underfitting*, di mana model belum cukup mempelajari pola fitur penyakit, sementara epoch yang berlebihan mengakibatkan *overfitting*, di mana model kehilangan kemampuan generalisasi pada data baru. Oleh karena itu, identifikasi jumlah epoch optimal menjadi faktor penentu dalam membangun model klasifikasi yang andal [1]. Beberapa penelitian terbaru juga menambahkan *attention mechanism* yang terbukti membantu model fokus pada area bercak penyakit guna meningkatkan akurasi serta efisiensi komputasi tanpa menambah kompleksitas model [2]. Selain klasifikasi, pendekatan lain seperti deteksi objek dan segmentasi citra juga terus dikembangkan untuk mengidentifikasi lokasi serta tingkat keparahan infeksi spesifik pada daun [3]. Model arsitektur seperti YOLO banyak digunakan karena mampu mendeteksi area terinfeksi dengan cepat dan presisi, bahkan pada citra dengan pencahayaan dan latar belakang yang rumit [4]. Dalam konteks penelitian ini, model MobileNetV2 dipilih karena memiliki struktur komputasi yang ringan dan efisien. Keunggulan ini menjadikannya sangat cocok untuk dianalisis pengaruh variasi epoch pelatihannya, sekaligus diterapkan pada perangkat dengan sumber daya terbatas seperti smartphone pertanian secara real-time [5].

Penelitian terdahulu menunjukkan variasi pendekatan *deep learning* dengan karakteristik performa yang berbeda. Ali dkk. mengembangkan AppleLeafNet, yaitu arsitektur CNN custom dengan 37 lapisan yang mampu mendiagnosis citra daun apel dengan akurasi tinggi namun memerlukan proses pelatihan menyeluruh karena dibangun tanpa menggunakan bobot pralatih (*pretrained weights*) [1]. Kondisi ini sejalan dengan model LCAMNet yang dirancang khusus untuk citra lingkungan alami, namun tetap memerlukan desain arsitektur manual dan pelatihan penuh tanpa bobot pralatih sehingga tantangan komputasinya serupa [6]. Pada pendekatan *transfer learning*, Rahman dkk. memanfaatkan VGG16 untuk klasifikasi penyakit daun apel dan melaporkan akurasi 99,31% setelah melakukan *fine-tuning* [7]. Penelitian tersebut dikembangkan oleh Gajjar dkk. dengan menambahkan modul MCBAM pada VGG16 hingga mencapai akurasi 99,8%, namun ukuran parameternya yang besar tetap menjadi kelemahan utama untuk perangkat

seluler [8]. Model CNN sederhana juga dikembangkan oleh Vishnoi dkk. untuk meningkatkan efisiensi komputasi pada dataset terkontrol [9], yang sejalan dengan studi Adriyanto dkk. dengan menerapkan tiga lapisan konvolusi dan filter bertingkat, meskipun kinerjanya menurun saat dihadapkan pada kompleksitas data lapangan nyata [10]. Selain itu, perbaikan pada model YOLOv5 juga diusulkan untuk meningkatkan akurasi deteksi bercak pada citra lingkungan alami [11], serta model CEFW-YOLO yang mampu memangkas kompleksitas komputasi sebesar 20,6% meskipun penerapannya pada perangkat mobile masih terbatas [12]. Berdasarkan celah riset tersebut, penelitian ini menawarkan solusi praktis dengan menganalisis pengaruh variasi jumlah epoch pelatihan terhadap performa model MobileNetV2 yang diimplementasikan pada antarmuka web sederhana, guna menemukan konfigurasi epoch optimal untuk klasifikasi penyakit daun apel di lingkungan nyata.

II. METODE

Penelitian ini menggunakan pendekatan *Development Research* (Penelitian Pengembangan) dengan menerapkan metode Waterfall sebagai model prosedural sistematis. Tahapan penelitian meliputi studi literatur, observasi lapangan di Kota Batu, analisa kebutuhan sistem, perancangan arsitektur, implementasi kode program, evaluasi performa model, pengujian fungsional, dan penyusunan laporan. Eksperimen pelatihan model *deep learning* dijalankan pada Kaggle Notebook yang didukung CPU Intel Xeon Processor dan GPU NVIDIA Tesla P100. Perangkat keras pendukung pengembangan sistem lokal menggunakan prosesor AMD Ryzen 3 5300U dengan RAM 12 GB. Lingkungan pemrograman dibangun menggunakan sistem operasi Windows 11, bahasa Python (library TensorFlow, Keras, dan Scikit-learn), serta framework Flask dengan HTML dan JavaScript untuk pengembangan antarmuka web sederhana sebagai media implementasi model klasifikasi.

Dataset dikumpulkan dari dua sumber utama, yaitu repositori publik Plant Pathology 2021 FGVC8 dan pengambilan gambar langsung di perkebunan apel Kota Batu, Malang. Kategori penyakit Apple Scab yang digunakan memiliki kompleksitas tekstur tinggi dengan gejala visual berupa bercak berwarna hijau zaitun hingga hitam dengan tepi tidak beraturan yang menuntut kemampuan ekstraksi fitur tekstur halus [13]. Sedangkan pada kelas Powdery Mildew, karakteristik utamanya terletak pada perubahan tekstur permukaan daun yang tertutup lapisan serbuk berwarna putih hingga abu-abu [14]. Total citra yang digunakan berjumlah 18.178 gambar berformat JPG yang terbagi menjadi lima kelas kondisi (Frogeye Leaf Spot, Healthy, Powdery Mildew, Rust, dan Scab). Dataset dibagi menjadi tiga subset menggunakan teknik *stratified random sampling* dengan proporsi rasio 70% data pelatihan (12.724 citra), 15% data validasi (2.727 citra), dan 15% data pengujian (2.727 citra).

Tahap pra-pemrosesan data (*preprocessing*) memanfaatkan pengolahan citra digital untuk mengekstraksi fitur warna, bentuk, dan tekstur objek berdasarkan manipulasi piksel dua dimensi [15]. Semua citra di-*resize* menjadi resolusi 320x320 piksel untuk menyesuaikan standar masukan lapisan konvolusi MobileNetV2. Nilai intensitas piksel citra dinormalisasi ke dalam rentang [0, 1] guna meningkatkan kestabilan pelatihan. Teknik augmentasi citra berupa rotasi, pembalikan horizontal (*flipping*), penyesuaian pencahayaan, dan perbesaran (*zooming*) diterapkan pada data latih. Proses pemrograman deep learning didukung oleh library Python seperti TensorFlow dan Keras yang memungkinkan perancangan model dilakukan secara efisien dan terstruktur [16].

Model komputasi inti menggunakan arsitektur MobileNetV2 yang memperkenalkan komponen *inverted residuals* dan *linear bottleneck* untuk menjaga representasi fitur penting agar tidak hilang selama proses kompresi [17]. Pelatihan dijalankan menggunakan fungsi loss Focal Loss dengan gamma 2.5 yang dioptimasi oleh algoritma AdamW (Adaptive Moment Estimation with Weight Decay) secara adaptif. Eksperimen variasi epoch dilakukan dalam tiga fase bertahap: Fase 1 (Feature Extraction, base frozen) dengan maksimum 50 epoch dan learning rate awal 1e-3; Fase 2 (Fine-tuning top 50% layer MobileNetV2) dengan maksimum 50 epoch dan learning rate 2e-5; serta Fase 3 (Full Unfreeze seluruh layer) dengan maksimum 30 epoch dan learning rate 3e-6. Setiap fase menggunakan cosine decay learning rate dengan linear warmup dan dikendalikan oleh mekanisme Early Stopping (patience=10) untuk mencegah overfitting secara otomatis pada saat epoch optimal tercapai.

A. Evaluasi

Evaluasi performa model klasifikasi dihitung secara kuantitatif berdasarkan representasi nilai dari Confusion Matrix. Ukuran performa dievaluasi melalui perhitungan matematis metrik Akurasi, Presisi, Recall, dan F1-Score menggunakan Persamaan (1), (2), (3), dan (4) berikut:

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

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

B. Desain Sistem dan Diagram

Arsitektur sistem ini dirancang untuk mengintegrasikan model MobileNetV2 hasil pelatihan dengan konfigurasi epoch optimal ke dalam antarmuka web sederhana berbasis Flask yang dapat diakses melalui browser. Desain eksperimen pelatihan dirancang secara bertahap menggunakan tiga fase epoch yang berbeda untuk menemukan konfigurasi optimal. Tahap awal mendefinisikan rentang epoch maksimum per fase (50-50-30 epoch), kemudian mekanisme Early Stopping secara otomatis menghentikan pelatihan saat tidak ada peningkatan val_accuracy dalam 10 epoch berturut-turut. Skenario variasi epoch ini dipetakan melalui kurva akurasi dan loss pelatihan untuk menganalisis perilaku konvergensi model dan mendeteksi gejala underfitting maupun overfitting pada setiap konfigurasi fase.


Tabel 1. Konfigurasi Eksperimen Variasi Epoch Pelatihan MobileNetV2

Fase	Konfigurasi Epoch			
	Max Epoch	Learning Rate	Epoch Aktual (Best)	Val Accuracy

Fase 1	Feature Extraction (base frozen)	50	1e-3	50 (best=50)	0.8141
Fase 2	Fine-tuning top 50% layer	50	2e-5	50 (best=41)	0.8940
Fase 3	Full Unfreeze	30	3e-6	11 (best=1)	0.8841


III. HASIL DAN PEMBAHASAN

Implementasi sistem diwujudkan melalui antarmuka web sederhana yang dibangun menggunakan framework Flask. Antarmuka ini memungkinkan pengguna mengunggah citra daun apel melalui browser, kemudian sistem melakukan pra-pemrosesan citra menjadi resolusi 320×320 piksel, menjalankan inferensi menggunakan model MobileNetV2 dengan konfigurasi epoch optimal, dan menampilkan hasil prediksi kelas penyakit beserta nilai confidence secara langsung. Tampilan antarmuka web disajikan pada Gambar 1.



Gambar 1. Tampilan Antarmuka Web

Proses pelatihan model dilakukan dalam tiga fase epoch secara bertahap. Kurva akurasi dan loss dari keseluruhan proses pelatihan disajikan pada Gambar 2 guna menganalisis perilaku konvergensi model pada setiap fase serta mendeteksi gejala underfitting maupun overfitting.



Gambar 2. Kurva Akurasi dan Loss Pelatihan Tiga Fase Epoch


Berdasarkan kurva pelatihan Gambar 2, Fase 1 (Feature Extraction, 50 epoch maksimum) menunjukkan konvergensi akurasi validasi yang stabil dengan Early Stopping menghentikan pelatihan secara otomatis pada epoch optimal. Fase 2 (Fine-tuning top 50% layer, 50 epoch maksimum) menghasilkan peningkatan akurasi yang signifikan karena lapisan atas MobileNetV2 mulai beradaptasi pada karakteristik visual penyakit daun apel. Fase 3 (Full Unfreeze, 30 epoch maksimum) memberikan penyesuaian fitur tingkat rendah secara menyeluruh sehingga model mencapai titik konvergensi terbaik. Penggunaan mekanisme Early Stopping (patience=10) pada setiap fase terbukti efektif mencegah overfitting, ditandai oleh gap antara kurva akurasi training dan validasi yang tetap minimal sepanjang proses pelatihan.

Evaluasi kinerja model dengan konfigurasi epoch optimal dilakukan menggunakan data pengujian independen sebanyak 2.727 citra daun apel. Berdasarkan hasil evaluasi kuantitatif, model MobileNetV2 berhasil mencapai akurasi 0.9025 (tanpa TTA) dan 0.9182 dengan TTA 20 varian (F1-Macro 0.9277). Laporan kinerja klasifikasi detail untuk setiap kelas kondisi daun apel disajikan dalam Tabel 2.

Tabel 2. Hasil Klasifikasi Model MobileNetV2 pada Konfigurasi Epoch Optimal

	Precision	Recall	F1-Score	Support
Frog_eye	0.8490	0.9003	0.8739	662
Healthy	0.9544	0.9900	0.9719	698
Powdery	0.9787	0.9634	0.9710	191
Rust	0.9355	0.9236	0.9295	314
Scab	0.9253	0.8619	0.8925	862
accuracy			0.9182	2727
macro avg	0.9286	0.9278	0.9277	2727
weighted avg	0.9191	0.9182	0.9181	2727

Merujuk pada Tabel 2, kategori Healthy memperoleh pencapaian tertinggi dengan nilai precision 0.9544, recall 0.9900, dan F1-Score 0.9719, yang menandakan kestabilan model dalam mengidentifikasi daun sehat karena konsistensi fitur warna hijau yang homogen. Kelas Rust juga menunjukkan performa seimbang dengan F1-Score sebesar 0.9295 berkat tingginya kontras warna oranye yang khas [1]. Kendala penurunan nilai performa terdeteksi pada kelas Frog_eye_leaf_spot (precision 0.8490) dan Scab (recall 0.8619). Untuk menganalisis galat atau kesalahan sebaran prediksi tersebut secara visual, dilakukan pemetaan sebaran data melalui Confusion Matrix pada Gambar 3.



Gambar 3. Confusion Matrix Hasil Klasifikasi Model MobileNetV2

Berdasarkan matriks sebaran Gambar 3, terlihat adanya tumpang tindih (*overlap*) fitur visual yang signifikan antara penyakit Scab dan Frog_eye_leaf_spot. Sebanyak 141 citra daun Scab salah diklasifikasikan sebagai Frog_eye_leaf_spot, dan sebaliknya, 17 citra Frog_eye_leaf_spot terprediksi keliru sebagai Scab. Secara teoritis, kesalahan klasifikasi ini dipicu oleh kemiripan karakteristik bercak lesi lokal berwarna gelap dengan batas geometri yang cenderung kabur pada fase infeksi awal [13]. Kapasitas ekstraksi spasial model MobileNetV2 yang ramping mengalami bias dalam membedakan tekstur beludru Scab dengan lesi konsentris Frogeye pada kondisi pencahayaan luar ruangan yang fluktuatif [6].

Kemudahan sistem dalam menerima masukan citra digital dari berbagai sumber gawai selaras dengan teori pengolahan citra digital dari Jumadi dkk. yang menyatakan bahwa manipulasi piksel dua dimensi memungkinkan perhitungan matematis yang stabil untuk mengekstraksi fitur visual esensial objek [15]. Di samping itu, efisiensi pemrosesan data di latar belakang juga didukung oleh ekosistem Python dari Riziq dkk. yang memfasilitasi integrasi model secara terstruktur [16]. Karakteristik efisiensi inferensi model MobileNetV2 yang dihasilkan dari konfigurasi epoch optimal pada antarmuka web [5]. Hal ini juga mendukung keunggulan arsitektur MobileNetV2 dari Wangsa Kencana & Umar yang membuktikan bahwa kombinasi teknik *inverted residuals* dan *linear bottleneck* mampu menghasilkan representasi fitur yang sangat efisien, stabil, dan ringan tanpa menurunkan kemampuan model dalam mengenali pola visual yang kompleks [17].

Melalui pencapaian konfigurasi epoch optimal tersebut, penelitian ini secara tegas menunjukkan ketidakefisienan implementasi model raksasa seperti VGG16 yang diusulkan oleh Rahman dkk. [7] dan Gajjar dkk. [8] karena ukuran parameternya yang besar mengakibatkan waktu konvergensi pelatihan yang jauh lebih panjang dan sulit dioptimalkan melalui variasi epoch. Di sisi lain, hasil eksperimen ini juga menunjukkan keterbatasan struktur CNN kustom sederhana yang diajukan oleh Adriyanto dkk. [10] serta model ringan milik Vishnoi dkk. [9] karena terbukti mengalami penurunan performa drastis akibat kegagalan generalisasi pola ketika dihadapkan pada kompleksitas variasi latar belakang alami di perkebunan nyata. Guna meningkatkan ketajaman diferensiasi detail halus bercak penyakit di masa mendatang tanpa mengorbankan kecepatan inferensi, arsitektur ringan ini dapat ditingkatkan dengan menambahkan mekanisme atensi seperti *Bottleneck Attention Module* (BAM-Net) sebagaimana disarankan oleh Gao dkk [2].

IV. KESIMPULAN

Penelitian ini berhasil menganalisis pengaruh variasi jumlah epoch pelatihan terhadap kinerja model *deep learning* MobileNetV2 dalam klasifikasi penyakit daun apel yang diimplementasikan pada antarmuka web sederhana. Hasil eksperimen menunjukkan bahwa konfigurasi epoch yang optimal secara langsung menentukan kemampuan konvergensi model dan mencegah overfitting pada data lapangan nyata. Pelatihan tiga fase bertahap dengan mekanisme Early Stopping menghasilkan model dengan akurasi 0.9025 (tanpa TTA) dan 0.9182 (dengan TTA 20 varian, F1-Macro 0.9277), dengan performa klasifikasi terbaik pada kategori Healthy (F1-Score 0.9719). Kendala utama klasifikasi terletak pada bias identifikasi antara kelas Scab dan Frogeye Leaf Spot akibat kemiripan karakteristik pola tekstur lesi pada fase infeksi awal, yang dapat diminimalkan lebih lanjut melalui penyesuaian konfigurasi epoch dan strategi augmentasi data. Secara keseluruhan, temuan ini membuktikan bahwa pemilihan jumlah epoch yang tepat pada setiap fase pelatihan merupakan faktor kunci dalam mengoptimalkan performa MobileNetV2 untuk klasifikasi penyakit daun apel secara akurat dan efisien..

DAFTAR PUSTAKA

- [1] M. U. Ali, M. Khalid, M. Farrash, H. F. M. Lahza, A. Zafar, and S. H. Kim, "AppleLeafNet: a lightweight and efficient deep learning framework for diagnosing apple leaf diseases," *Front. Plant Sci.*, vol. 15, 2024, doi: 10.3389/fpls.2024.1502314.
- [2] Y. Gao, Z. Cao, W. Cai, G. Gong, G. Zhou, and L. Li, "Apple Leaf Disease Identification in Complex Background Based on BAM-Net," *Agronomy*, vol. 13, no. 5, May 2023, doi: 10.3390/agronomy13051240.
- [3] J. Wang, J. Jia, Y. Zhang, H. Wang, and S. Zhu, "RAAWC-UNet: an apple leaf and disease segmentation method based on residual attention and atrous spatial pyramid pooling improved UNet with weight compression loss," *Front. Plant Sci.*, vol. 15, 2024, doi: 10.3389/fpls.2024.1305358.
- [4] T. Li, L. Zhang, and J. Lin, "Precision agriculture with YOLO-Leaf: advanced methods for detecting apple leaf diseases," *Front. Plant Sci.*, vol. 15, 2024, doi: 10.3389/fpls.2024.1452502.
- [5] M. G. Somoal and A. R. Dzikrillah, "Komparasi MobileNETV2 dengan Kustomisasi Transfer Learning dan Hyperparameter untuk Identifikasi Tumor Otak," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 12, no. 1, pp. 229–240, Feb. 2025, doi: 10.25126/jtiik.2025129582.
- [6] Y. Jiao *et al.*, "LCAMNet: a lightweight model for apple leaf disease classification in natural environments," *Front. Plant Sci.*, vol. 16, 2025, doi: 10.3389/fpls.2025.1626569.
- [7] A. T. Rahman, A. Setyanto, and H. Al Fatta, "Klasifikasi Penyakit Daun Apel Menggunakan Arsitektur CNN Dengan Transfer Learning," 2024, doi: 10.31284/j.senopati.2024.v6i1.6574.
- [8] P. C. Gajjar, H. N. Dalal, H. K. Patel, and N. K. Prajapati, "Modified Convolutional Block Attention Mechanism-Based VGG16 for Apple Plant Leaf Disease Classification," *SSRG*

- International Journal of Electronics and Communication Engineering*, vol. 11, no. 8, pp. 62–71, Aug. 2024, doi: 10.14445/23488549/IJECE-V11I8P107.
- [9] V. K. Vishnoi, K. Kumar, B. Kumar, S. Mohan, and A. A. Khan, “Detection of Apple Plant Diseases Using Leaf Images Through Convolutional Neural Network,” *IEEE Access*, vol. 11, pp. 6594–6609, 2023, doi: 10.1109/ACCESS.2022.3232917.
- [10] T. Adriyanto, R. A. Ramadhani, R. Helilintar, and A. Ristyawan, “Classification of Dog and Cat Images using the CNN Method,” *ILKOM Jurnal Ilmiah*, vol. 14, no. 3, pp. 203–208, Dec. 2022, doi: 10.33096/ilkom.v14i3.1116.203-208.
- [11] Z. Liu and X. Li, “An improved YOLOv5-based apple leaf disease detection method,” *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-67924-8.
- [12] J. Tao, X. Li, Y. He, and M. A. Islam, “CEFW-YOLO: A High-Precision Model for Plant Leaf Disease Detection in Natural Environments,” *Agriculture (Switzerland)*, vol. 15, no. 8, Apr. 2025, doi: 10.3390/agriculture15080833.
- [13] B. Liu, H. Fan, Y. Zhang, J. Cai, and H. Cheng, “Deep learning architectures for diagnosing the severity of apple frog-eye leaf spot disease in complex backgrounds,” *Front. Plant Sci.*, vol. 14, 2023, doi: 10.3389/fpls.2023.1289497.
- [14] G. M. Guzu, S. D. Roşu Mareş, C. Moldovan, I. Zagrai, L. A. Zagrai, and M. I. Cordea, “Results of some apple hybrid populations to the attack of scab and powdery mildew under natural conditions,” *Romanian journal of Horticulture*, vol. 5, pp. 77–84, Dec. 2024, doi: 10.51258/RJH.2024.09.
- [15] J. Jumadi, Y. Yupianti, and D. Sartika, “PENGOLAHAN CITRA DIGITAL UNTUK IDENTIFIKASI OBJEK MENGGUNAKAN METODE HIERARCHICAL AGGLOMERATIVE CLUSTERING,” *JST (Jurnal Sains Dan Teknologi)*, vol. 10, no. 2, 2021, doi: 10.23887/jstundiksha.v10i2.33636.
- [16] M. Riziq sirfatullah Alfarizi, M. Zidan Al-farish, M. Taufiqurrahman, G. Ardiansah, and M. Elgar, “PENGUNAAN PYTHON SEBAGAI BAHASA PEMROGRAMAN UNTUK MACHINE LEARNING DAN DEEP LEARNING,” 2023, doi: 10.30997/karimahtauhid.v2i1.7518
- [17] N. Wangsa Kencana and R. Umar, “Implementasi Transfer Learning Untuk Klasifikasi Jenis Ras Ayam Menggunakan Arsitektur MobileNetV2,” *JIP (Jurnal Informatika Polinema)*, vol. 11, no. 2, 2025, doi: 10.33795/jip.v11i2.6469.