

ANALISIS PERBANDINGAN MODEL ARSITEKTUR *MOBILENETV2* DAN *EFFICIENTNETB3* DALAM KLASIFIKASI PENYAKIT DAUN JAGUNG

Kadek Agus Tamayasa¹, Luh Joni Erawati Dewi²

^{1,2}Program Studi Ilmu Komputer, Universitas Pendidikan Ganesha; Jl. Udayana No.11, Singaraja, Kabupaten Buleleng, Bali 81116

Keywords:

Penyakit Daun Jagung;
Convolutional Neural Network; *MobileNetV2*;
EfficientNetB3; Klasifikasi.

Correspondent Email:

agustamayasa21@gmail.com

Abstrak. Jagung merupakan komoditas pertanian strategis nasional yang produktivitasnya sering menurun akibat serangan penyakit daun, seperti bercak daun, karat daun, dan hawar daun. Identifikasi penyakit secara manual bersifat subjektif dan kurang efisien, sehingga diperlukan pendekatan otomatis berbasis deep learning. Penelitian ini bertujuan membandingkan kinerja arsitektur *Convolutional Neural Network* (CNN) *MobileNetV2* dan *EfficientNetB3* dalam klasifikasi penyakit daun jagung. Dataset yang digunakan terdiri atas 2.000 citra daun jagung dari Kaggle yang melalui tahapan pembersihan, pemisahan, resize dan augmentasi, serta dilatih menggunakan variasi batch size dan jumlah epoch. Hasil eksperimen menunjukkan bahwa *MobileNetV2* mencapai performa terbaik pada konfigurasi batch size 32 dan epoch 50 dengan akurasi pelatihan 99,85%, validasi 97,22%, dan pengujian 96,50%. Sementara itu, *EfficientNetB3* memperoleh performa optimal pada batch size 16 dan epoch 50 dengan akurasi pelatihan 94,23%, validasi 92,22%, dan pengujian 93,00%. Temuan ini menunjukkan bahwa *MobileNetV2* lebih efektif dan stabil untuk pengembangan sistem deteksi dini penyakit daun jagung berbasis citra.



Copyright © [JITET](http://jitet.umsida.ac.id) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. Corn is a strategic national agricultural commodity whose productivity often declines due to leaf diseases, such as leaf spot, leaf rust, and leaf blight. Manual disease identification is subjective and inefficient, requiring an automated approach based on deep learning. This study aims to compare the performance of the *MobileNetV2* and *EfficientNetB3* *Convolutional Neural Network* (CNN) architectures in classifying corn leaf diseases. The dataset used consisted of 2,000 corn leaf images from Kaggle that underwent cleaning, separation, resizing, and augmentation, and were trained using variations in batch size and number of epochs. The results of the experiment show that *MobileNetV2* achieved the best performance with a batch size of 32 and 50 epochs, with a training accuracy of 99.85%, validation accuracy of 97.22%, and testing accuracy of 96.50%. Meanwhile, *EfficientNetB3* achieved optimal performance at a batch size of 16 and 50 epochs with a training accuracy of 94.23%, validation accuracy of 92.22%, and testing accuracy of 93.00%. These findings indicate that *MobileNetV2* is more effective and stable for developing an image-based early detection system for corn leaf diseases.

1. PENDAHULUAN

Jagung merupakan salah satu komoditas pangan yang menduduki posisi penting di dunia, setelah padi dan gandum. Di Indonesia, jagung juga merupakan kebutuhan pangan yang sangat vital, sejajar dengan pentingnya padi [1]. Menurut data Badan Pusat Statistik Indonesia, konsumsi jagung secara nasional terus menunjukkan tren peningkatan dari tahun ke tahun. Pada tahun 2023, konsumsi jagung mencapai sekitar 22,9 juta ton, meningkat rata-rata 3,6% per tahun dari tahun 2019 hingga 2023. Ketersediaan jagung yang cukup dan berkualitas berperan penting dalam menjaga ketahanan pangan, mendukung industri peternakan yang berkembang, dan meningkatkan perekonomian negara secara keseluruhan.

Jagung bukan hanya menjadi sumber karbohidrat yang penting, tetapi juga bahan baku untuk berbagai produk makanan dan minuman, serta pakan ternak. Sebagaimana dikemukakan oleh peneliti terdahulu, bahwa dalam ilmu botani, klasifikasi tanaman merupakan komponen fundamental yang berkontribusi terhadap upaya pelestarian dan pengembangan spesies tanaman secara berkelanjutan [2]. Idealnya, produksi jagung nasional mampu memenuhi kebutuhan konsumsi domestik dan bahkan surplus untuk ekspor. Hal ini akan meningkatkan ketahanan pangan nasional dan memberikan peluang ekspor yang menguntungkan bagi petani. Namun, pada tahun 2023 menurut BPS, produksi jagung nasional hanya mencapai 14,77 juta ton, masih di bawah kebutuhan konsumsi domestik. Salah satu hambatan utama dalam meningkatkan produksi jagung adalah serangan penyakit, khususnya pada daun jagung. Terdapat tiga jenis penyakit pada daun jagung yang menjadi perhatian utama, yaitu penyakit karat daun, penyakit bercak daun, dan penyakit hawar daun [3].

Identifikasi penyakit pada tanaman jagung umumnya dilakukan melalui pengamatan langsung terhadap kondisi fisik daun. Metode ini mengandalkan kemampuan visual manusia untuk menilai perubahan warna atau pola pada permukaan daun yang menjadi indikator adanya infeksi penyakit. Namun, cara tersebut memiliki sejumlah keterbatasan, terutama ketika dilakukan pada area lahan yang luas dan melibatkan banyak tanaman. Selain

membutuhkan waktu yang lama, penilaian visual juga bersifat subjektif karena hasilnya dapat berbeda antar pengamat [4]. Keterbatasan ini menimbulkan kebutuhan akan metode yang lebih efisien, objektif, dan terotomatisasi. Salah satu solusi potensial adalah penerapan teknologi pengolahan citra digital berbasis kecerdasan buatan, khususnya melalui pendekatan *deep learning*.

Penerapan *deep learning* dalam bidang pertanian, terutama untuk deteksi penyakit tanaman, telah menjadi topik penelitian yang semakin berkembang. Metode ini mampu mempelajari representasi kompleks dari data citra daun secara otomatis, sehingga dapat meningkatkan akurasi dan kecepatan proses identifikasi penyakit. Dengan kata lain, *deep learning* memungkinkan pembangunan sistem klasifikasi penyakit daun yang lebih efisien, handal, dan adaptif terhadap variasi citra yang dihasilkan dari kondisi lapangan [5]. Khususnya, dengan memanfaatkan metode *Convolutional Neural Network*, sistem dapat belajar untuk mengenali pola-pola yang terkait dengan penyakit daun jagung secara otomatis dari data citra tanaman.

Convolutional Neural Network (CNN) adalah sebuah metode dalam bidang *deep learning* yang mampu mengekstraksi fitur-fitur penting secara otomatis dan hierarkis langsung dari data gambar mentah. Metode ini telah menunjukkan performa yang unggul dalam berbagai aplikasi pengenalan pola, termasuk identifikasi penyakit pada daun tanaman [6]. Dibandingkan dengan metode lain seperti *Multi Layer Perceptron* (MLP), CNN memiliki kemampuan lebih baik dalam mengenali struktur spasial gambar karena arsitekturnya yang mendalam dan terorganisasi secara hierarkis. Kedalaman jaringan memungkinkan CNN untuk mempelajari fitur tingkat rendah hingga tinggi secara berlapis, sehingga menghasilkan akurasi klasifikasi yang lebih optimal [7]. Terdapat beberapa turunan dari CNN, beberapa diantaranya adalah *MobileNet* dan *EfficientNet*.

MobileNetV2 merupakan modifikasi dari model *MobileNet* sebelumnya yang memperkenalkan perubahan signifikan. Perbedaan utamanya terletak pada penerapan *inverted residual blocks* dan *linear bottleneck*, yang memungkinkan model mengubah representasi data dari tingkat rendah seperti

piksel menjadi fitur yang lebih bermakna dan berdimensi tinggi [8]. Arsitektur ini memanfaatkan *depthwise separable convolution* untuk mengurangi jumlah parameter dan mempercepat proses inferensi tanpa menurunkan performa. *MobileNetV2* terbukti mampu memberikan akurasi yang baik meskipun menggunakan dataset terbatas, menjadikannya salah satu model yang efisien dan andal untuk berbagai aplikasi pengenalan citra [9].

EfficientNetB3 merupakan salah satu model CNN yang dikenal memiliki kemampuan luar biasa dalam memprediksi dan mengklasifikasikan objek dengan tingkat akurasi yang tinggi. Keunggulan utama dari *EfficientNetB3* adalah penggunaan strategi *compound scaling* yang mengoptimalkan jaringan dengan memperbesar dimensi kedalaman, lebar, dan resolusi secara seimbang. Dengan jaringan yang lebih luas, lebih besar, lebih lebar, lebih dalam, dan memiliki resolusi yang lebih tinggi, *EfficientNetB3* dapat mencapai akurasi yang lebih baik dibandingkan model lainnya [10].

Terdapat beberapa penelitian terdahulu terkait klasifikasi citra yang relevan. Penelitian dari [11] melakukan “Klasifikasi Penyakit Daun Jagung Menggunakan Metode *Convolutional Neural Network AlexNet*”, yang menghasilkan tingkat akurasi data *testing* sebesar 90%. Penelitian lainnya yang relevan dalam klasifikasi daun dilakukan oleh [12] dengan judul “*Convolutional Neural Network* Pada Identifikasi Varian Tanaman Anggur Menggunakan *Resnet-50*”, mendapatkan tingkat akurasi tertinggi sebesar 86% pada tahap *training* dan 91% pada tahap validasi. Serta error yang terjadi pada masing-masing proses *training* dan validasi adalah 0.26 dan 0.17. Penelitian selanjutnya dilakukan oleh [13] dengan judul “Implementasi Model Arsitektur *VGG16* dan *MobileNetV2* Untuk Klasifikasi Citra Kupu-Kupu”, hasilnya menunjukkan bahwa arsitektur *MobileNetV2* memiliki performa yang lebih baik daripada arsitektur *VGG16*. Dalam penelitian tersebut, *MobileNetV2* berhasil mencapai tingkat akurasi tertinggi, yakni mencapai 96%, tanpa perlu *fine-tuning*.

Berdasarkan latar belakang yang telah diuraikan, penelitian ini mencoba untuk menerapkan metode CNN dengan model

arsitektur *MobileNetV2* dan *EfficientNetB3* dalam klasifikasi jenis penyakit pada daun jagung yang mencakup penyakit karat daun, penyakit bercak daun, penyakit hawar daun, dan daun sehat. Fokus penelitian ini adalah pada proses klasifikasi citra daun yang bertujuan untuk menghasilkan model yang dapat membedakan berbagai jenis penyakit yang umum terjadi pada daun jagung.

2. TINJAUAN PUSTAKA

2.1 Jenis Penyakit Daun Jagung

Jagung adalah salah satu tanaman pangan penting yang dibudidayakan secara luas di berbagai belahan dunia. Tanaman ini merupakan sumber karbohidrat utama selain beras dan gandum. Selain sebagai bahan pangan, jagung juga memiliki berbagai kegunaan lain seperti pakan ternak, bahan baku industri, dan energi bio [14]. Dalam proses budidaya jagung, penyakit daun jagung seringkali menjadi salah satu kendala utama yang dapat menurunkan produktivitas tanaman. Penyakit-penyakit ini disebabkan oleh berbagai agen patogen, seperti jamur, bakteri, dan virus. Beberapa jenis penyakit daun jagung yang umum dijumpai antara lain.

Penyakit Karat Daun, gejala utamanya adalah munculnya pustula berwarna jingga hingga cokelat pada permukaan daun. Pustula ini sering kali memanjang sejajar dengan tulang daun, yang disebabkan oleh jamur *Puccinia sorghi* [15]. Penyakit Bercak Daun, gejala yang muncul berupa bercak kecil berwarna cokelat hingga hitam yang kemudian membesar dan bergabung menjadi bercak yang lebih besar. Bercak-bercak ini sering kali dikelilingi oleh halo berwarna kuning, yang disebabkan oleh jamur *Cercospora zeae-maydis*. Penyakit Hawar Daun, gejala utama adalah munculnya bercak berbentuk elips berwarna cokelat gelap hingga abu-abu pada daun. Bercak-bercak ini dapat menyebar dengan cepat di bawah kondisi lembap, yang disebabkan oleh jamur *Exserohilum turcicum*.


2.2 Deep Learning

Deep Learning merupakan cabang dari *machine learning* yang berfokus pada pengembangan model komputasi dengan kemampuan untuk mempelajari representasi data yang bersifat kompleks dan abstrak secara otomatis [16]. Pendekatan ini bekerja dengan

memanfaatkan jaringan saraf buatan yang memiliki banyak lapisan tersembunyi untuk mengekstraksi fitur-fitur penting dari data secara bertingkat. Dengan menambah jumlah lapisan atau memperdalam arsitektur jaringan, kemampuan sistem dalam mengenali pola serta meningkatkan akurasi komputasi menjadi lebih optimal [17]. Struktur jaringan yang dalam tersebut memungkinkan sistem untuk memahami hubungan non-linear antar data, sehingga efektif digunakan dalam berbagai permasalahan klasifikasi citra, suara, maupun teks.

2.3 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *deep learning* yang dirancang untuk mengolah dan menganalisis data visual seperti citra maupun video. Jaringan ini memiliki beberapa komponen utama, yaitu *Convolutional Layer*, *Pooling Layer*, dan *Fully Connected Layer*, yang bekerja secara berurutan untuk mengekstraksi serta mengenali fitur penting dari citra input [18]. CNN dikenal sebagai metode *deep learning* yang memberikan hasil paling signifikan karena memiliki sistem pengenalan citra yang meniru cara kerja penglihatan manusia, sehingga mampu memproses dan memahami informasi visual secara efisien [19]. Melalui operasi konvolusi, jaringan ini dapat mendeteksi pola visual seperti tepi, tekstur, dan bentuk objek tanpa memerlukan proses ekstraksi fitur secara manual. Lapisan *Pooling* berfungsi untuk mereduksi ukuran data sambil mempertahankan informasi penting, sedangkan *Fully Connected Layer* bertugas mengklasifikasikan hasil ekstraksi fitur menjadi kategori tertentu.




Gambar 1. Arsitektur CNN [18].

2.4 MobilenetV2

MobileNetV2 merupakan arsitektur *deep learning* yang dikembangkan untuk menghasilkan model jaringan yang efisien namun tetap memiliki akurasi tinggi dalam tugas pengenalan citra. Arsitektur ini

mengintegrasikan dua komponen penting, yaitu *Linear Bottleneck* dan *Shortcut Connection*, yang berfungsi menjaga proses ekstraksi fitur tetap optimal tanpa kehilangan banyak informasi penting [20]. *Linear Bottleneck* berperan dalam mempertahankan representasi fitur pada dimensi yang lebih rendah, sehingga dapat mengurangi kompleksitas komputasi tanpa mengorbankan kualitas hasil.

Selain itu, *Shortcut Connection* memiliki peran penting dalam memperlancar aliran gradien selama proses pelatihan jaringan, sehingga stabilitas model dapat terjaga dengan baik. *MobileNetV2* juga memanfaatkan *depthwise separable convolution*, yaitu bentuk konvolusi yang menghasilkan keluaran serupa dengan konvolusi standar namun dengan jumlah parameter yang jauh lebih sedikit [21]. Pendekatan ini menjadikan *MobileNetV2* efisien dalam memproses data citra dengan tetap mempertahankan kemampuan representasi fitur yang mendalam.




Gambar 2. Arsitektur MobilenetV2 [22].

2.5 EfficientNetB3

EfficientNetB3 adalah salah satu varian dari keluarga model *EfficientNet* yang mampu memprediksi dan mengklasifikasi objek dengan tingkat akurasi tinggi. Hal ini dikarenakan jaringan yang dimilikinya lebih luas, dengan peningkatan pada lebar, ukuran, kedalaman, serta resolusi, faktor-faktor ini berkontribusi terhadap pencapaian akurasi yang lebih tinggi [23]. *EfficientNetB3* memiliki arsitektur yang dimulai dengan lapisan konvolusi 3x3 diikuti *batch normalization* dan *Swish activation* [10]. Setelah itu, model mengaplikasikan beberapa blok *Mobile Inverted Bottleneck Convolution* (MBConv) dengan kernel yang bervariasi antara 3x3 dan 5x5, serta konfigurasi *squeeze-and-excitation* (SE) dan *linear bottleneck*. Tiap MBConv berulang kali memperkecil resolusi spatial sambil meningkatkan jumlah fitur hingga mencapai ukuran 7x7. Kemudian, fitur ini diproses oleh lapisan konvolusi 1x1 sebelum diikuti oleh *global average pooling* (GAP) dan

fully connected layer yang akhirnya menerapkan softmax untuk klasifikasi.



Gambar 3. Arsitektur *EfficientNetB3* [24].

2.6 Confusion Matrix

Confusion Matrix merupakan metode evaluasi yang digunakan untuk menilai kinerja model klasifikasi secara komprehensif dengan mempertimbangkan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* [25]. Melalui matriks ini, dapat diketahui posisi kesalahan prediksi model berdasarkan empat komponen utama, yaitu *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN).

		ACTUAL VALUES	
		1 (Positive)	0 (Negative)
PREDICTED VALUES	1 (Positive)	TP (True Positive)	FP (False Positive)
	0 (Negative)	FN (False Negative)	TN (True Negative)

Gambar 4. *Confusion matrix*

Accuracy menunjukkan seberapa besar proporsi prediksi yang benar dibandingkan dengan keseluruhan data yang diuji. *Precision* menilai sejauh mana model mampu memprediksi kelas positif secara tepat, sedangkan *recall* menggambarkan kemampuan model dalam menemukan seluruh sampel positif yang sebenarnya ada. Untuk memperoleh keseimbangan antara ketepatan dan kelengkapan prediksi, digunakan metrik *F1-score* yang memberikan evaluasi lebih seimbang terhadap performa model. Berikut merupakan rumus perhitungan dari masing-masing komponen tersebut.

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


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

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

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

3. METODE PENELITIAN

Penelitian ini dilaksanakan melalui lima tahapan utama, mulai dari pengumpulan data hingga evaluasi kinerja model. Rangkaian tahapan tersebut disusun secara sistematis untuk mendukung pelaksanaan proses klasifikasi secara menyeluruh dan terukur.



Gambar 5. Tahapan Penelitian

3.1 Pengumpulan Data

Data penelitian diperoleh dari repositori *PlantVillage* di platform *Kaggle*, yang menyediakan citra daun jagung dalam format .JPG. Dataset mencakup berbagai kondisi daun sehat maupun yang terinfeksi penyakit, dengan total 2.000 citra yang digunakan sebagai dasar proses klasifikasi.

3.2 Preprocessing Data

Tahap *preprocessing* diawali dengan pembersihan data. Tahap ini mencakup penghapusan gambar yang tidak relevan atau tidak akurat sehingga hanya data berkualitas yang dipertahankan dalam proses pemodelan [26]. Selanjutnya, dataset dibagi menjadi data pelatihan sebesar 90% dan data pengujian sebesar 10%. Seluruh citra kemudian diseragamkan ke ukuran 224×224 piksel agar sesuai dengan kebutuhan input arsitektur jaringan yang digunakan. Tahap berikutnya adalah augmentasi data, yang digunakan untuk menambah variasi visual sehingga model dapat mengenali pola dari gambar yang tampil dalam bentuk berbeda dan meningkatkan kemampuan generalisasi ketika dihadapkan pada data baru [27]. Teknik augmentasi yang diterapkan meliputi *horizontal flip*, *vertical flip*, dan rotasi acak.

3.3 Perancangan Model

Model *MobileNetV2* diinisialisasi menggunakan bobot pra-latih *ImageNet* dengan seluruh parameter bersifat *trainable* agar mampu beradaptasi secara optimal terhadap karakteristik data latih. Bagian klasifikasi

(*custom head*) diawali dengan lapisan *Global Average Pooling* yang diikuti oleh *Batch Normalization*. Selanjutnya, fitur diproses melalui dua lapisan *Dense* berurutan dengan 256 dan 128 neuron, masing-masing dilengkapi aktivasi *ReLU*, *Batch Normalization*, dan *Dropout* sebesar 0,3 untuk mengurangi risiko *overfitting*. Proses klasifikasi diakhiri dengan lapisan *Dense* beraktivasi *Softmax* yang menghasilkan empat kelas keluaran.

Pada model *EfficientNetB3* diinisialisasi menggunakan bobot pra-latih *ImageNet* dengan fokus utama sebagai ekstraktor fitur berkapasitas tinggi. Berbeda dari *MobileNetV2*, arsitektur ini menggunakan rancangan *custom head* yang lebih sederhana namun *regularized*, diawali dengan *Global Average Pooling* untuk merangkum fitur spasial, kemudian dilanjutkan dengan *Batch Normalization* dan *Dropout* sebesar 0,4. Representasi fitur selanjutnya dipetakan melalui satu lapisan *Dense* berukuran 256 neuron dengan aktivasi *ReLU*, yang kembali diperkuat oleh *Batch Normalization* dan *Dropout* guna meningkatkan kemampuan generalisasi. Tahap akhir klasifikasi menggunakan lapisan *Dense* beraktivasi *Softmax*.

3.4 Pelatihan Model

Tahap pelatihan model dilakukan dengan menerapkan beberapa skenario *hyperparameter* untuk memperoleh konfigurasi yang paling optimal. Proses pelatihan menggunakan *optimizer Adam* dengan *learning rate* sebesar 0.0001 serta fungsi *loss categorical crossentropy*. Variasi pelatihan mencakup dua ukuran *batch*, yaitu 16 dan 32, serta dua jumlah *epoch*, yaitu 25 dan 50, sebagaimana dirangkum pada Tabel 1. Perbedaan kombinasi *hyperparameter* ini dirancang untuk mengamati respons masing-masing arsitektur terhadap perubahan durasi pelatihan dan jumlah data yang diproses pada setiap iterasi.

Tabel 1. Skenario *Hyperparameter* Pelatihan

Skenario	Batch Size	Epoch
1	16	25
2		50
3	32	25
4		50

Untuk menilai efektivitas setiap konfigurasi, seluruh skenario diuji menggunakan data uji dan dievaluasi berdasarkan metrik akurasi,

presisi, *recall*, dan *F1-score*. Seluruh pengujian diterapkan secara konsisten pada kedua arsitektur yang digunakan sehingga performa masing-masing model dapat dianalisis dan dibandingkan secara objektif.


3.5 Evaluasi Model

Kinerja model pada setiap skenario dievaluasi menggunakan *confusion matrix* untuk menganalisis kesesuaian antara hasil prediksi dan label sebenarnya pada data pengujian. Melalui representasi ini, performa model dapat diamati berdasarkan distribusi prediksi benar dan salah, termasuk *true positive*, *true negative*, *false positive*, dan *false negative* pada masing-masing kelas. Evaluasi dilakukan menggunakan data uji yang tidak dilibatkan selama proses pelatihan, sehingga memberikan gambaran objektif mengenai kemampuan model dalam mengenali pola penyakit daun jagung.

4. HASIL DAN PEMBAHASAN

4.1 Dataset

Dataset yang digunakan mencakup empat kategori kondisi daun jagung, yaitu bercak daun, karat daun, hawar daun, dan daun sehat. Masing-masing kelas berisi 500 citra sehingga total keseluruhan data berjumlah 2.000 gambar yang menjadi objek analisis pada tahap pelatihan dan pengujian model.



Bercak daun Hawar daun Karat daun Daun Sehat

Gambar 6. Sample dataset penyakit daun jagung


4.2 Preprocessing Data

Pada tahap *preprocessing*, sebagian kecil citra dieliminasi karena buram, orientasi tidak konsisten, atau tidak merepresentasikan kelas yang benar. Tahapan selanjutnya dilakukan pemisahan dataset, dataset dipisahkan menjadi dua kelompok utama, yakni data pelatihan sebesar 90% atau (1.800 citra), dan data pengujian sebesar 10% atau (200 citra). Setiap kelas berkontribusi secara proporsional, masing-masing terdiri atas 450 citra pada data pelatihan dan 50 citra pada data pengujian.



Gambar 7. Pemisahan data latih dan uji

Tahap berikutnya adalah standarisasi ukuran citra. Seluruh gambar diubah menjadi resolusi 224×224 piksel untuk menyesuaikan format input pada kedua arsitektur CNN yang digunakan. Setelah itu, augmentasi diterapkan pada seluruh data pelatihan melalui teknik horizontal *flip*, vertical *flip*, dan rotasi acak, sebagaimana ditunjukkan pada Gambar 8. Penerapan ketiga teknik tersebut pada setiap citra meningkatkan jumlah data pelatihan dari 1.800 menjadi 7.200 citra.




Gambar 8. Implementasi teknik augmentasi

4.3 Pelatihan model

4.4.1 Pelatihan Model MobileNetV2


Berdasarkan serangkaian skenario eksperimen yang telah dilakukan, konfigurasi *hyperparameter* terbaik untuk model *MobileNetV2* diperoleh pada penggunaan *batch size* 32 dan *epoch* 25. Konfigurasi ini menghasilkan akurasi pelatihan dan validasi tertinggi sekaligus menunjukkan proses pelatihan yang paling stabil dibandingkan dengan skenario lainnya.

Gambar 9. Grafik Akurasi *MobileNetV2* (Batch Size 32, Epoch 50)

Visualisasi pada Gambar 9 menggambarkan dinamika pembelajaran *MobileNetV2* yang menunjukkan tren peningkatan akurasi secara progresif dan stabil sepanjang 50 *epoch*

pelatihan. Pada fase awal pelatihan hingga *epoch* ke-10, terjadi peningkatan akurasi yang sangat signifikan dimana model mampu beradaptasi cepat mengenali fitur citra daun jagung dengan akurasi pelatihan mencapai 92,60% dan validasi sebesar 93,33%. Memasuki pertengahan proses pelatihan, tren kenaikan mulai melandai namun menunjukkan konsistensi yang tinggi, dimana celah antara akurasi pelatihan dan validasi sangat tipis yang mengindikasikan model berada dalam kondisi *good fit*.

Stabilitas model semakin terlihat jelas setelah melewati *epoch* ke-20, dimana garis validasi bergerak konstan sejajar dengan garis pelatihan pada rentang nilai yang tinggi menandakan bahwa model telah mencapai titik konvergensi yang optimal. Hingga akhir proses pelatihan pada *epoch* ke-50, akurasi pelatihan mencapai sekitar 99,80%, sementara akurasi validasi stabil pada sekitar 97,20%, yang menunjukkan bahwa model mampu mempertahankan performa tinggi pada data yang tidak pernah dilihat sebelumnya.

Gambar 10. Grafik *Loss MobileNetV2* (Batch Size 32, Epoch 50)

Sejalan dengan peningkatan akurasi tersebut, kurva *loss* pada Gambar 10 memperlihatkan pola penurunan yang konsisten dan signifikan seiring bertambahnya iterasi pelatihan. Terlihat bahwa *loss* validasi mengalami penurunan drastis pada 10 *epoch* pertama dan berhasil mencapai konvergensi dengan *loss* pelatihan di angka yang sangat rendah mendekati nol mulai *epoch* ke-20. Hingga akhir proses pelatihan, nilai *loss* pelatihan berhasil ditekan hingga angka 0,0131 sementara *loss* validasi bertahan rendah pada 0,0738, menegaskan kemampuan model mampu meminimalkan error prediksi secara optimal tanpa mengalami gejala *overfitting*.


Skenario	Batch Size	Epoch	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
1	16	25	95.50	95.56	95.50	95.51
2		50	96.00	95.98	96.00	95.98
3	32	25	95.50	95.40	95.50	95.49
4		50	96.50	96.49	96.50	96.49

Gambar 11. Perbandingan Hasil Pengujian *MobileNetV2*

Hasil pengujian yang ditampilkan pada Gambar 11 menegaskan bahwa arsitektur *MobileNetV2* menunjukkan kinerja yang sangat kompetitif dalam mengklasifikasikan penyakit daun jagung. Seluruh skenario pengujian secara konsisten menghasilkan tingkat akurasi di atas 95%, yang mengindikasikan bahwa model mampu mengekstraksi fitur pembeda antar kelas penyakit dengan baik. Kinerja paling optimal dicapai pada skenario 4, yang mencatatkan akurasi tertinggi sebesar 96.50%, dengan nilai *Precision*, *Recall*, dan *F1-Score* yang sangat seimbang di angka 96.49%. Sementara itu, hasil terendah tercatat pada Skenario 1 dan 3 dengan akurasi 95.50%. Sempitnya rentang perbedaan antara performa terendah dan tertinggi (selisih 1%) menunjukkan bahwa model memiliki stabilitas yang baik, meskipun konfigurasi parameter tertentu terbukti mampu memaksimalkan potensi akurasi model hingga mencapai puncaknya.

4.4.2 Pelatihan Model *EfficientNetB3*

Proses pelatihan *EfficientNetB3* dilakukan dengan menerapkan beberapa *hyperparameter* untuk mengidentifikasi konfigurasi yang memberikan kinerja paling optimal. Hasil terbaik diperoleh ketika model dilatih menggunakan *batch size* 16 dan *epoch* 50, yang menghasilkan akurasi pelatihan dan validasi tertinggi dibandingkan konfigurasi lainnya.




Gambar 12. Grafik Akurasi *EfficientNetB3* (Batch Size 16, Epoch 50)

Visualisasi pada Gambar 12 memperlihatkan karakteristik pembelajaran

EfficientNetB3 yang cenderung fluktuatif, khususnya pada fase awal hingga pertengahan proses pelatihan. Berbeda dengan model sebelumnya, stabilitas akurasi validasi pada 20 *epoch* pertama terlihat sangat dinamis, dimana terjadi penurunan tajam hingga ke kisaran 60% pada *epoch* ke-9 dan ke-15 meskipun sempat menyentuh angka yang lebih tinggi. Kondisi ini mengindikasikan bahwa model dengan arsitektur yang lebih kompleks membutuhkan proses iterasi yang lebih panjang untuk menyesuaikan bobotnya dalam mengenali pola fitur penyakit secara konsisten.

Performa mulai bergerak stabil dan menanjak secara perlahan setelah melewati *epoch* ke-30, ditandai dengan peningkatan akurasi validasi yang bertahap dan semakin mendekati akurasi pelatihan. Pada akhir proses pelatihan, model berhasil mencapai titik konvergensi yang baik dengan mencatatkan akurasi pelatihan sebesar 94,23% dan validasi 92,22%. Hasil akhir ini menunjukkan bahwa meskipun mengalami kesulitan adaptasi di tahap awal, model tetap mampu mencapai kemampuan generalisasi yang optimal tanpa indikasi overfitting yang signifikan.



Gambar 13. Grafik Loss *EfficientNetB3* (Batch Size 16, Epoch 50)

Kurva *loss* pada Gambar 13 menunjukkan bahwa pada awal pelatihan *loss* validasi mengalami fluktuasi besar dengan beberapa lonjakan hingga sekitar *epoch* ke-15 sebelum mulai menurun. Setelah melewati *epoch* ke-25, *loss* validasi menjadi lebih stabil meskipun tetap berada pada jarak tertentu dari *loss* pelatihan. Hingga akhir, *loss* pelatihan tercatat 0,1641 dan *loss* validasi 0,3084. Hal ini menunjukkan bahwa model berhasil melewati fase awal yang tidak stabil dan mencapai performa yang cukup konsisten.

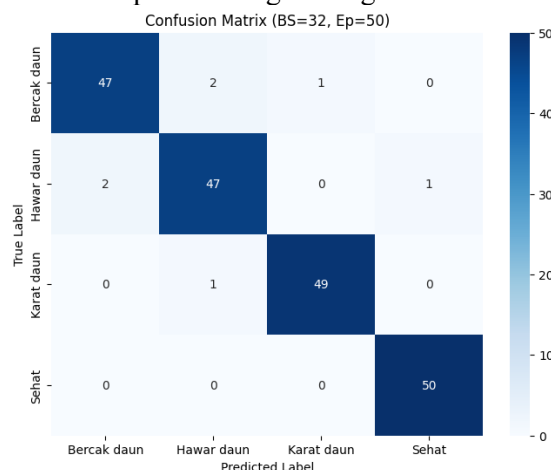
Skenario	Batch Size	Epoch	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
1	16	25	92.00	92.00	92.00	91.99
2		50	93.00	93.00	93.00	93.00
3	32	25	91.00	90.92	91.00	90.88
4		50	92.00	92.00	92.00	92.00

Gambar 14. Perbandingan Hasil Pengujian *EfficientNetB3*

Hasil pengujian yang ditampilkan pada Gambar 14 memperlihatkan bahwa arsitektur *EfficientNetB3* mampu mengklasifikasikan penyakit daun jagung dengan tingkat akurasi yang cukup baik, yaitu berada pada rentang 91.00% hingga 93.00%. Capaian performa tertinggi diraih pada Skenario 2 dengan *batch size* 16 dan *epoch* 50, yang mencatatkan nilai konsisten pada seluruh metrik evaluasi (Akurasi, *Precision*, *Recall*, dan *F1-Score*) sebesar 93.00%. Di sisi lain, performa terendah tercatat pada Skenario 3 dengan akurasi 91.00% dan *F1-Score* 90.88%. Temuan ini mengindikasikan bahwa peningkatan *batch size* tidak selalu menghasilkan performa yang lebih baik, bahkan *batch size* 16 terbukti memberikan hasil yang lebih optimal dibandingkan 32 pada jumlah *epoch* yang sama.

4.4 Evaluasi Model


Pada tahap evaluasi, kinerja model diuji menggunakan data uji yang terdiri dari 50 citra. Hasil prediksi yang diperoleh selanjutnya dianalisis dan disajikan dalam bentuk *confusion matrix* untuk memberikan gambaran awal mengenai kemampuan model dalam melakukan klasifikasi pada masing-masing kelas.



Gambar 15. *Confusion matrix MobileNetV2* (Batch Size 32, Epoch 50)

Confusion matrix pada Gambar 15 menunjukkan bahwa model *MobileNetV2*

mampu mengklasifikasikan sebagian besar data uji dengan tingkat ketepatan yang sangat baik, yang tercermin dari dominasi nilai *true positive* pada diagonal utama. Kinerja paling optimal ditunjukkan pada kelas sehat yang teridentifikasi secara sempurna (50/50), diikuti oleh kelas karat daun dengan hanya satu kesalahan prediksi. Misklasifikasi dalam jumlah kecil terjadi antara kelas bercak daun dan hawar daun, kemungkinan dipengaruhi kemiripan fitur visual keduanya. Secara keseluruhan, minimnya kesalahan di luar diagonal utama mengindikasikan kemampuan *MobileNetV2* yang kuat dalam membedakan setiap kelas kondisi daun jagung.



Gambar 16. *Confusion matrix EfficientNetB3* (Batch Size 16, Epoch 50)

Confusion matrix pada Gambar 16 memperlihatkan bahwa *EfficientNetB3* mampu mengidentifikasi kelas sehat secara sempurna, konsisten dengan hasil yang diperoleh *MobileNetV2*. Namun, tingkat kesalahan klasifikasi terlihat lebih tinggi pada kelas bercak daun dan hawar daun, yang ditandai oleh meningkatnya prediksi silang antara kedua kelas tersebut. Nilai *true positive* pada masing-masing kelas tercatat sebanyak 44 data, lebih rendah dibandingkan *MobileNetV2*, sehingga menunjukkan sensitivitas yang relatif lebih rendah dalam membedakan kedua penyakit tersebut. Meskipun demikian, kinerja pada kelas karat daun tetap stabil dengan 48 prediksi benar, menandakan bahwa *EfficientNetB3* masih mampu mempertahankan akurasi yang baik pada kategori tertentu.

4.5 Pengaruh Batch Size dan Jumlah Epoch Terhadap Performa Model

Secara keseluruhan, variasi *batch size* dan jumlah *epoch* menunjukkan pengaruh yang jelas terhadap performa akhir model. Pada *MobileNetV2*, peningkatan *epoch* dari 25 menjadi 50 memberikan dampak positif yang konsisten pada kedua konfigurasi *batch*. Kenaikan paling menonjol terlihat pada *batch size* 32, dengan akurasi meningkat sebesar 1% dari 95,50% pada *epoch* 25 menjadi 96,50% pada *epoch* 50. Temuan ini menunjukkan bahwa *MobileNetV2* merespons lebih optimal terhadap stabilitas gradien yang diperoleh dari *batch* yang lebih besar, terutama ketika didukung durasi pelatihan yang cukup untuk mencapai konvergensi. Sebaliknya, penggunaan *batch size* 16 hanya menghasilkan peningkatan marjinal sebesar 0,50% (95,50% menjadi 96,00%), menandakan bahwa konfigurasi ini cenderung mencapai batas kemampuan model lebih cepat.

Berbeda dengan pola tersebut, *EfficientNetB3* menunjukkan tren yang berlawanan. Pembesaran ukuran *batch* justru menurunkan performa, di mana *batch size* 16 secara konsisten mengungguli *batch size* 32 pada seluruh skenario. Selisih akurasi tercatat sebesar 1,00% pada *epoch* 25 (92,00% vs 91,00%) maupun *epoch* 50 (93,00% vs 92,00%). Meskipun demikian, peningkatan *epoch* tetap memberikan kontribusi positif, ditunjukkan oleh kenaikan akurasi sebesar 1% pada kedua konfigurasi *batch*. Hasil ini mengindikasikan bahwa *EfficientNetB3* lebih efektif melakukan generalisasi ketika pembaruan bobot dilakukan secara lebih sering melalui *batch* kecil, dibandingkan akumulasi gradien pada *batch* besar.

4.6 Perbandingan antara model MobileNetV2 dan EfficientNetB3

Berdasarkan seluruh skenario eksperimen yang dilakukan, *MobileNetV2* menunjukkan kinerja yang lebih unggul dibandingkan *EfficientNetB3* dalam klasifikasi penyakit daun jagung. Pada tahap pelatihan, *MobileNetV2* mencapai akurasi pelatihan sebesar 99,85% dan validasi 97,22%, lebih tinggi dibandingkan *EfficientNetB3* yang mencatatkan akurasi pelatihan 94,23% dan validasi 92,22%. Keunggulan tersebut berlanjut pada tahap pengujian, di mana *MobileNetV2* meraih

akurasi tertinggi sebesar 96,50% pada konfigurasi *batch size* 32 dan *epoch* 50, sementara *EfficientNetB3* mencapai akurasi terbaik sebesar 93,00% pada *batch size* 16 dan *epoch* 50.

Hasil analisis dari *confusion matrix* memperkuat hasil perbandingan kedua model. *MobileNetV2* menampilkan tingkat kesalahan yang lebih rendah pada kelas bercak daun dan hawar daun, serta hanya satu misklasifikasi pada kelas karat daun. Sebaliknya, *EfficientNetB3* mengalami misklasifikasi yang lebih tinggi pada kelas bercak daun dan hawar daun dengan nilai *true positive* masing-masing sebesar 44, meskipun kinerjanya pada kelas karat daun tetap stabil dengan 48 prediksi benar. Perbedaan ini menegaskan bahwa *MobileNetV2* memiliki kemampuan generalisasi dan ketepatan klasifikasi yang lebih konsisten pada dataset penelitian ini.

5. KESIMPULAN

- a. Arsitektur *MobileNetV2* terbukti memberikan kinerja yang lebih unggul dibandingkan *EfficientNetB3*, dengan akurasi pelatihan mencapai 99,85% dan akurasi validasi sebesar 97,22%, serta akurasi pengujian tertinggi 96,50% pada konfigurasi *batch size* 32 dan *epoch* 50. Capaian ini melampaui performa terbaik *EfficientNetB3* yang hanya memperoleh akurasi pelatihan 94,23%, akurasi validasi 92,22%, dan akurasi pengujian 93,00% pada konfigurasi optimal *batch size* 16 dan *epoch* 50. Hasil tersebut menegaskan bahwa *MobileNetV2* lebih efektif dalam mengekstraksi fitur visual penyakit daun jagung dengan proses konvergensi yang lebih cepat dan stabil.
- b. Analisis *hyperparameter* menunjukkan bahwa *MobileNetV2* mencapai performa terbaik pada *batch size* (32) dengan jumlah *epoch* ditingkatkan, menandakan kemampuannya memanfaatkan akumulasi gradien secara efektif untuk mencapai konvergensi yang stabil. Sebaliknya, *EfficientNetB3* mengalami penurunan performa pada *batch size* besar dan bekerja lebih optimal dengan *batch size* (16), yang menunjukkan kebutuhan pembaruan bobot yang lebih sering pada arsitektur kompleks. Temuan ini menegaskan bahwa kompleksitas model tidak selalu

menghasilkan performa lebih baik pada dataset seperti dalam penelitian ini.

- c. Meskipun kedua model menunjukkan performa yang kompetitif, penelitian ini memiliki keterbatasan pada kedekatan fitur visual antara kelas bercak daun dan hawar daun yang memicu misklasifikasi pada hasil prediksi. Untuk penelitian selanjutnya, disarankan memperluas cakupan dataset dengan kondisi lingkungan yang lebih beragam serta mengeksplorasi teknik augmentasi lanjutan atau integrasi mekanisme attention guna meningkatkan kemampuan model dalam membedakan kelas dengan kemiripan visual yang tinggi.

UCAPAN TERIMA KASIH

Penulis menyampaikan apresiasi dan terima kasih kepada seluruh pihak yang telah memberikan dukungan, bantuan, serta kontribusi selama pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- [1] B. Widiyanto, E. Utami, and D. Ariatmanto, "Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network Identification of Corn Plant Diseases Based on Leaf Image Using Convolutional Neural Network," *Agustus*, vol. 22, no. 3, pp. 599–608, 2023.
- [2] S. I. A. P. Pande, Putu Ony Andewi, Gede Arya Ardivan Pratama Saputra, Werdyana Guna Mertha, and Agus Aan Jiwa Permana, "Klasifikasi Tanaman Pinus Berbasis Forward," *JPTE J. Pendidik. Tek. Elektro*, vol. 13, no. 11, pp. 142–156, 2024.
- [3] N. P. Dita Ariani Sukma Dewi, I. G. Hendrayana, and I Wayan Agus Weda Kusuma Putra, "Optimasi Hyperparameter Convolutional Neural Network Dengan Arsitektur Mobilenet Pada Klasifikasi Penyakit Daun Jagung," *J. Mnemon.*, vol. 8, no. 1, pp. 92–99, 2025, doi: 10.36040/mnemonic.v8i1.11744.
- [4] M. I. Rosadi and M. Lutfi, "Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model," *J. Explor. IT!*, vol. 13, no. 2, pp. 36–42, 2021, [Online]. Available: <https://doi.org/10.35891/explorit>
- [5] A. B. Prakosa, Hendry, and R. Tanone, "Implementasi Model Deep Learning Convolutional Neural Network (CNN) Pada Citra Penyakit Daun Jagung Untuk Klasifikasi Penyakit Tanaman," *J. Pendidik. Teknol. Inf.*, vol. 6, no. 1, pp. 107–116, 2023.
- [6] W. Maximilliano and N. Rachmat, "Comparative Analysis of MobileNetV3-Large and Small for Corn Leaf Disease Classification," *Brill. Res. Artif. Intell.*, vol. 5, no. 1, pp. 325–332, 2025, doi: 10.47709/brilliance.v5i1.6259.
- [7] I. P. Putra, R. Rusbandi, and D. Alamsyah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network," *J. Algoritma.*, vol. 2, no. 2, pp. 102–112, 2022, doi: 10.35957/algoritme.v2i2.2360.
- [8] H. Herwina, D. Darmatasia, A. K. A. Shiddiq, and T. D. Syahputra, "Deteksi Penyakit pada Tanaman Padi Menggunakan MobileNet Transfer Learning Berbasis Android," *Jagti*, vol. 2, no. 2, pp. 1–8, 2022, [Online]. Available: <https://tin.fst.uin-alauddin.ac.id/jurnal/index.php/agents/article/view/41>
- [9] F. B. Pasaribu, L. J. E. Dewi, K. Y. E. Aryanto, and P. Varnakovidia, "Effect of Synthetic Data Augmentation on Plant Classification Accuracy Using MobileNetV2, EfficientNet-B0, and ResNet-18," *2025 IEEE 5th Int. Conf. Softw. Eng. Artif. Intell. SEAI 2025*, pp. 1–6, 2025, doi: 10.1109/SEAI65851.2025.11108883.
- [10] F. Zaelani and Y. Miftahuddin, "Perbandingan Metode EfficientNetB3 dan MobileNetV2 Untuk Identifikasi Jenis Buah-buahan Menggunakan Fitur Daun," *J. Ilm. Teknol. Infomasi Terap.*, vol. 9, no. 1, pp. 1–11, 2022, doi: 10.33197/jitter.vol9.iss1.2022.911.
- [11] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *sudo J. Tek. Inform.*, vol. 2, no. 1, pp. 28–33, 2023, doi: 10.56211/sudo.v2i1.227.
- [12] M. A. N. Hidayat, Kusri, and Hanafi, "Convolutional Neural Network Pada Identifikasi Varian Tanaman Anggur Menggunakan Resnet-50," *J. Tek. Inform. dan Sist. Inf.*, vol. 10, no. 3, pp. 61–70, 2023, [Online]. Available: <https://jurnal.mdp.ac.id/index.php/jatisi/article/download/4789/1531>
- [13] D. Ramayanti, D. Asri, and L. Lionie, "Implementasi Model Arsitektur VGG16 dan MobileNetV2 Untuk Klasifikasi Citra Kupu-Kupu Article Info ABSTRAK," *JSAI J. Sci. Appl. Informatics*, vol. 5, no. 3, pp. 182–187, 2022.
- [14] W. G. Pamungkas, M. Iqbal, P. Wardhana, Z. Sari, and Y. Azhar, "JURNAL RESTI," vol. 5, no. 158, pp. 326–333, 2023.
- [15] F. Rajeena P. P., A. S. U., M. A. Moustafa, and M. A. S. Ali, "Detecting Plant Disease in Corn Leaf Using EfficientNet Architecture—An

- Analytical Approach,” *Electron.*, vol. 12, no. 8, 2023, doi: 10.3390/electronics12081938.
- [16] M. Fauzan Novriandy, B. Rahmat, and A. Junaidi, “Klasifikasi Citra Penyakit Kanker Mulut Menggunakan Arsitektur Resnet50 Optimasi Adam Dan Sgd,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, 2024, doi: 10.23960/jitet.v12i3.4732.
- [17] N. P. K. Dewi, P. H. Suputra, A. A. G. Y. Paramartha, L. J. E. Dewi, P. Varnakovidia, and K. Y. E. Aryanto, “River Area Segmentation Using Sentinel-1 SAR Imagery with Deep-Learning Approach,” *Geomatics Environ. Eng.*, vol. 19, no. 4, pp. 39–63, 2025, doi: 10.7494/geom.2025.19.4.39.
- [18] S. Muhammad Syadham and M. Akbar, “Klasifikasi Citra Biji Kopi Temanggung Menggunakan Gray Level Co-Ocurrence Matrix – Convolutional Neural Network,” *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 3, 2025, doi: 10.23960/jitet.v13i3.7274.
- [19] 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,” *Indones. J. Artif. Intell. Data Min.*, vol. 8, no. 1, p. 86, 2024, doi: 10.24014/ijaidm.v8i1.31620.
- [20] S. S. Rambe, A. Asriyanik, and P. Prajoko, “Penerapan Model Convolutional Neural Network (Cnn) Berbasis Mobilenetv2 Untuk,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 13, no. 3, 2025.
- [21] Y. Aufar and T. P. Kaloka, “Robusta coffee leaf diseases detection based on MobileNetV2 model,” *Int. J. Electr. Comput. Eng.*, vol. 12, no. 6, pp. 6675–6683, 2022, doi: 10.11591/ijece.v12i6.pp6675-6683.
- [22] F. A. Arafat, D. P. Pamungkas, and P. Kasih, “Pemodelan Klasifikasi Penyakit Daun Tembakau Dengan Arsitektur MobileNetV2,” vol. 9, pp. 2549–7952, 2025.
- [23] E. Anggiratih, S. Siswanti, S. K. Octaviani, and A. Sari, “Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning,” *J. Ilm. SINUS*, vol. 19, no. 1, p. 75, 2021, doi: 10.30646/sinus.v19i1.526.
- [24] H. Alhichri, A. S. Alswayed, Y. Bazi, N. Ammour, and N. A. Alajlan, “Classification of Remote Sensing Images Using EfficientNetB3 CNN Model with Attention,” *IEEE Access*, vol. 9, pp. 14078–14094, 2021, doi: 10.1109/ACCESS.2021.3051085.
- [25] I. K. N. Ananda, N. Putu, N. Puspa, N. W. Marti, L. Joni, and E. Dewi, “JOURNAL OF APPLIED COMPUTER SCIENCE AND TECHNOLOGY (JACOST) Klasifikasi Multilabel Pada Gaya Belajar Siswa Sekolah Dasar Menggunakan Algoritma Machine Learning,” vol. 5, no. 2, pp. 144–154, 2024.
- [26] D. Prima, H. Putri, N. Putu, N. Puspa, I. K. Purnamawan, and N. W. Marti, “Perbandingan Performansi Support Vector Machine (Svm) dan Backpropagation untuk Klasifikasi Studi,” vol. 9, no. 3, pp. 492–501, 2023.
- [27] I. M. G. Vedanty, Putu Prianka, Kesiman, Made Windu Antara, Sunarya, “PENGARUH DATA AUGMENTASI PADA IDENTIFIKASI PENYAKIT DAUN TANAMAN OBAT MENGGUNAKAN K-NEAREST NEIGHBOR,” vol. 9, no. 2, pp. 2094–2100, 2025.