

Analisis Pengaruh Augmentasi Data pada Model MobileNetV3-Large untuk Klasifikasi Penyakit Daun Labu Manis

Sokhibul Amin ^{1*}, Miftahus Sholihin ², Munif ³

^{1,2,3} Program Studi Teknik Informatika, Universitas Islam Lamongan, Indonesia

¹ sokhibamin1@gmail.com, ² miftahus.sholihin@unisla.ac.id, ³ munif@unisla.ac.id

Diajukan: 13/5/2026 | Direvisi: 15/06/2026 | Diterima: 17/6/2026 | Diterbitkan: 30/6/2026

Abstrak

Tanaman labu manis (*Cucurbita moschata*) merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi, namun produktivitasnya sering mengalami penurunan akibat serangan berbagai penyakit daun. Identifikasi penyakit secara manual masih memiliki keterbatasan karena bersifat subjektif, membutuhkan waktu, dan kurang efisien pada area pertanian yang luas. Penelitian ini bertujuan untuk menganalisis pengaruh penerapan augmentasi data terhadap performa klasifikasi penyakit daun labu manis menggunakan model MobileNetV3-Large dengan dukungan teknik optimasi *Early Stopping* dan *Learning Rate Scheduler*. Dataset yang digunakan terdiri dari 1.000 citra yang mencakup lima kelas, yaitu *Healthy Leaf*, *Downy Mildew*, *Leaf Curl*, *Mosaic Disease*, dan *Red Beetle*. Dataset dibagi menggunakan rasio 80:10:10 untuk data latih, validasi, dan pengujian. Penelitian dilakukan melalui dua skenario, yaitu penggunaan dataset orisinal dan dataset hasil augmentasi. Hasil eksperimen menunjukkan bahwa model pada skenario pertama menghasilkan akurasi sebesar 85,00%, sedangkan pada skenario kedua mengalami peningkatan menjadi 88,00%. Nilai *precision*, *recall*, dan *F1-score* juga meningkat dari 86%, 85%, dan 85% menjadi 87%, 87%, dan 87%. Selain itu, ukuran model tetap ringan sebesar 15 MB pada kedua skenario. Hasil penelitian menunjukkan bahwa kombinasi model MobileNetV3-Large, augmentasi data, *Early Stopping*, dan *Learning Rate Scheduler* mampu meningkatkan kemampuan generalisasi model sekaligus mempertahankan efisiensi komputasi.

Kata Kunci: Augmentasi Data, Deep Learning, Klasifikasi, Mobilenetv3-Large, Penyakit Daun Labu Manis.

Abstract

Sweet pumpkin (*Cucurbita moschata*) is a horticultural commodity with high economic value, but its productivity has frequently decreased due to various leaf diseases. Manual disease identification still has several limitations because it is subjective, time-consuming, and inefficient for large-scale agricultural areas. This study aimed to analyze the effect of data augmentation on sweet pumpkin leaf disease classification performance using the MobileNetV3-Large model supported by *Early Stopping* and *Learning Rate Scheduler* optimization techniques. The dataset consisted of 1,000 images representing five classes, namely *Healthy Leaf*, *Downy Mildew*, *Leaf Curl*, *Mosaic Disease*, and *Red Beetle*. The dataset was divided into training, validation, and testing subsets using an 80:10:10 ratio. Two experimental scenarios were conducted, namely using the original dataset and the augmented dataset. The experimental results showed that the first scenario achieved an accuracy of 85.00%, while the second scenario improved the accuracy to 88.00%. The precision, recall, and F1-score values also increased from 86%, 85%, and 85% to 87%, 87%, and 87%, respectively. In addition, the model size remained lightweight at 15 MB in both scenarios. The results indicated that the combination of the MobileNetV3-Large model, data data augmentation, *Early Stopping*, and *Learning Rate Scheduler* successfully improved model generalization while maintaining computational efficiency.

Keywords: Classification, Data Augmentation, Deep Learning, Mobilenetv3-Large, Sweet Pumpkin Leaf Disease.



This work is an open access article and licensed under a Creative Commons Attribution-NonCommercial ShareAlike 4.0 International (CC BY-NC-SA 4.0). Copyright (C) Authors.

1. PENDAHULUAN

Tanaman labu manis (*Cucurbita moschata*) merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi serta kandungan nutrisi yang bermanfaat bagi kesehatan manusia [1]. Selain dimanfaatkan sebagai bahan pangan, tanaman ini juga memiliki potensi pengembangan pada sektor industri pangan dan kesehatan. Namun, produktivitas tanaman labu manis sering mengalami penurunan akibat serangan berbagai penyakit daun seperti *Downy*

Mildew, Leaf Curl, Mosaic Disease, serta serangan hama *Red Beetle*. Gejala penyakit tersebut umumnya ditandai dengan perubahan warna, tekstur, maupun bentuk daun yang secara langsung menghambat proses fotosintesis dan pertumbuhan tanaman. Apabila tidak dideteksi dan ditangani secara dini, kondisi tersebut dapat menyebabkan penurunan kualitas maupun kuantitas hasil panen secara signifikan serta menimbulkan kerugian ekonomi bagi petani [1].

Identifikasi penyakit daun pada tanaman labu manis di tingkat petani hingga saat ini masih banyak dilakukan melalui pengamatan visual secara manual [1]. Pendekatan konvensional tersebut memiliki berbagai keterbatasan, seperti ketergantungan terhadap pengalaman pengamat, tingkat subjektivitas yang tinggi, serta potensi kesalahan diagnosis terutama pada penyakit yang memiliki kemiripan gejala visual pada fase awal infeksi. Selain itu, proses pengamatan manual juga kurang efisien ketika diterapkan pada area pertanian dengan skala yang luas. Oleh karena itu, diperlukan sistem identifikasi otomatis yang mampu melakukan klasifikasi penyakit daun secara cepat, objektif, dan konsisten.

Perkembangan teknologi *Artificial Intelligence* khususnya *Deep Learning* telah membuka peluang besar dalam pengembangan sistem klasifikasi citra otomatis di bidang pertanian [2] [3]. Berbagai penelitian terbaru juga menunjukkan bahwa model *deep learning* ringan mampu memberikan performa klasifikasi yang tinggi untuk identifikasi penyakit tanaman dengan efisiensi komputasi yang baik [4]. Salah satu pendekatan yang banyak digunakan adalah model *Convolutional Neural Network* (CNN), yang mampu mengekstraksi fitur visual secara hierarkis langsung dari citra mentah [5] [6]. Pengembangan model *Convolutional Neural Network* (CNN) juga terbukti efektif dalam mendeteksi berbagai penyakit tanaman secara otomatis dengan tingkat akurasi yang tinggi [7]. Penerapan model *Convolutional Neural Network* (CNN) pada klasifikasi penyakit tanaman telah menunjukkan performa klasifikasi yang sangat baik, dengan akurasi mencapai 99,19% pada klasifikasi penyakit daun tomat. Selain itu, pendekatan *transfer learning* yang dikombinasikan dengan strategi optimasi pelatihan juga dilaporkan mampu mencapai akurasi sebesar 99,09% pada klasifikasi penyakit daun anggur, sehingga menunjukkan potensi besar *deep learning* dalam mendukung sistem pertanian cerdas [8] [9].

Model *Convolutional Neural Network* (CNN) sangat dipengaruhi oleh kualitas dan jumlah dataset yang digunakan. Dataset dengan jumlah sampel terbatas sering menyebabkan model mengalami *overfitting*, yaitu kondisi ketika model memiliki performa klasifikasi yang tinggi pada data pelatihan tetapi kurang mampu melakukan generalisasi pada data baru [10]. Salah satu teknik yang banyak digunakan untuk mengatasi permasalahan tersebut adalah augmentasi data. Teknik ini menghasilkan variasi citra baru melalui transformasi seperti rotasi, *flipping*, translasi, dan *zoom* tanpa perlu melakukan pengambilan data tambahan secara langsung. Penerapan augmentasi data terbukti mampu meningkatkan kemampuan generalisasi model dan menghasilkan performa klasifikasi yang lebih stabil pada berbagai kasus klasifikasi citra pertanian [10]. Selain itu, penerapan augmentasi data secara eksperimental juga dilaporkan mampu meningkatkan akurasi model secara signifikan pada dataset dengan jumlah sampel terbatas [11] [12].

Dalam pengembangan sistem klasifikasi berbasis *transfer learning*, pemilihan model juga menjadi faktor penting. Salah satu model ringan yang banyak digunakan adalah model MobileNetV3-Large. Model ini dirancang menggunakan mekanisme *depthwise separable convolution* yang mampu menurunkan kompleksitas komputasi secara signifikan tanpa mengorbankan performa klasifikasi. Model MobileNetV3-Large dilaporkan mampu menghasilkan akurasi tinggi dengan ukuran model yang relatif kecil, sehingga sangat potensial untuk diterapkan pada perangkat *mobile* maupun *edge computing* di lingkungan pertanian [13]. Implementasi model MobileNetV3-Large pada berbagai kasus klasifikasi penyakit tanaman juga menunjukkan performa yang stabil dengan tingkat akurasi yang tinggi [14] [15].


Stabilitas proses pelatihan juga menjadi faktor penting dalam menghasilkan model klasifikasi yang optimal. Teknik optimasi seperti *Early Stopping* dan *Learning Rate Scheduler* terbukti mampu menjaga stabilitas proses pelatihan, mencegah *overfitting*, serta membantu model mencapai titik konvergensi yang optimal dengan waktu pelatihan yang lebih efisien [16] [17].

Berdasarkan kajian literatur sebelumnya, penelitian mengenai klasifikasi penyakit daun labu manis sebagian besar masih berfokus pada penggunaan model berukuran besar seperti DenseNet-121 [1] [5] atau ResNet50 [18] yang membutuhkan sumber daya komputasi tinggi serta dataset yang berskala besar. Keterbatasan sumber daya dan ukuran dataset seringkali menjadi kendala dalam praktik komputasi sebenarnya. Oleh karena itu, terdapat celah penelitian (*research gap*) terkait evaluasi komprehensif mengenai performa model ringan ketika dihadapkan pada dataset terbatas. Kontribusi ilmiah utama dari penelitian ini adalah mengisi celah tersebut dengan mengevaluasi secara empiris sejauh mana teknik augmentasi data dapat meningkatkan performa klasifikasi ringan tanpa mengorbankan efisiensi komputasi.

Tujuan dari penelitian ini secara eksplisit adalah untuk menganalisis pengaruh penerapan augmentasi data terhadap performa klasifikasi penyakit daun labu manis menggunakan model MobileNetV3-Large, dengan dukungan optimasi *Early Stopping* dan *Learning Rate Scheduler*. Evaluasi secara ketat dibatasi pada pengujian komparatif antara skenario dataset orisinal dan dataset hasil augmentasi berdasarkan metrik *accuracy*, *precision*, *recall*, *F1-score*, ukuran model, serta efisiensi waktu komputasi per *epoch*.

2. METODE PENELITIAN

Penelitian ini dilaksanakan melalui tahapan sistematis untuk menganalisis pengaruh augmentasi data pada performa klasifikasi model MobileNetV3-Large dalam klasifikasi penyakit daun labu manis. Alur kerja penelitian difokuskan pada perbandingan dua skenario utama untuk mencapai efisiensi dan akurasi optimal, sebagaimana diilustrasikan pada Gambar 1.



Gambar 1. Alur Penelitian

Tahap pertama adalah pengumpulan data, di mana dataset "*Sweet Pumpkin Disease Recognition*" diperoleh dari platform Mendeley Data yang mencakup lima kelas penyakit daun labu manis. Seluruh citra melalui proses seleksi ketat untuk memastikan validitas label dan kualitas visual sebelum melanjutkan ke fase berikutnya.

Tahap kedua meliputi pra-pengolahan dan augmentasi data, di mana seluruh citra diubah ukurannya menjadi 224 x 224 piksel dan dinormalisasi sesuai standar model MobileNetV3-Large. Untuk meminimalisir risiko *overfitting* pada salah satu skenario, teknik augmentasi seperti rotasi dan *flipping* diterapkan guna meningkatkan jumlah sampel dari 160 menjadi 600 citra per kelas.

Tahap ketiga adalah pelatihan model MobileNetV3-Large melalui pendekatan *Transfer Learning* dengan membandingkan dua skenario utama, yaitu data orisinal dan augmentasi data. Kedua skenario ini secara mutlak mengintegrasikan teknik optimasi *Early Stopping* dan *Learning Rate Scheduler* untuk menjaga stabilitas konvergensi dan mencapai hasil pelatihan yang optimal.

Tahap keempat berfokus pada evaluasi model menggunakan metrik yang meliputi *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Selain performa klasifikasi, dilakukan analisis efisiensi komputasi dengan membandingkan waktu pelatihan per *epoch* dan ukuran penyimpanan berkas model akhir guna menilai kelayakannya pada perangkat *edge computing*.

Tahap terakhir adalah implementasi sistem, di mana skenario eksperimen terbaik diintegrasikan ke dalam antarmuka web menggunakan *framework* Flask. Fase ini berfungsi untuk menguji performa fungsional model dalam aplikasi dunia nyata, yang memungkinkan pengguna mendapatkan hasil diagnosis instan beserta skor tingkat kepercayaan setelah mengunggah citra daun labu manis.

2.1. Pengumpulan dan Pembagian Dataset

Dataset yang digunakan dalam penelitian ini adalah *Sweet Pumpkin Disease Recognition Dataset* dari Mendeley Data <https://data.mendeley.com/datasets/7397w9h5tb/1> [19]. Data terdiri dari 1.000 citra asli yang mencakup lima kategori: *Healthy Leaf*, *Downy Mildew*, *Leaf Curl*, *Mosaic*, dan *Red Beetle*. Peneliti menggunakan folder *Original Images* untuk memastikan kontrol penuh terhadap proses augmentasi pada tahap pra-pengolahan guna menghindari bias model.

Seluruh dataset dibagi ke dalam tiga subset utama dengan rasio 80:10:10. Pembagian dilakukan secara manual dengan tetap mempertahankan proporsi yang seimbang pada setiap kelas (*stratified*) guna menjamin objektivitas pada tahap pelatihan dan pengujian. Rincian distribusi data setelah pembagian disajikan pada Tabel 1. Sebagai berikut:

Tabel 1. Distribusi Pembagian Dataset

Kelas	Latih (80%)	Validasi (10%)	Uji (10%)	Total Citra
Healthy Leaf	160	20	20	200
Downy Mildew	160	20	20	200
Leaf Curl	160	20	20	200
Mosaic	160	20	20	200
Red Beetle	160	20	20	200
Total	800	100	100	1000

Sedangkan representasi visual dari sampel setiap kelas ditunjukkan pada Gambar 2. sebagai berikut:




Gambar 2. Contoh Lima Kelas Daun Labu Manis

2.2. Pra-pengolahan dan Augmentasi Data

Tahap pra-pengolahan dilakukan untuk memastikan citra berada dalam kondisi optimal bagi model. Proses ini diawali dengan penyesuaian dimensi citra (*resizing*) menjadi 224 x 224 piksel sesuai dengan standar masukan model MobileNetV3-Large. Normalisasi nilai piksel dilakukan secara dinamis menggunakan fungsi `preprocess_input` dari *library* TensorFlow Keras yang disesuaikan dengan standar teknis MobileNetV3 guna mempercepat konvergensi dan menjaga stabilitas pembelajaran.

Untuk memperkaya variabilitas data dan meminimalisir risiko *overfitting*, teknik augmentasi diterapkan secara *offline* khusus pada subset data latih. Parameter augmentasi meliputi rotasi acak (20°), pergeseran lebar dan tinggi (0,2), serta *horizontal flip*. Area piksel kosong hasil transformasi diisi menggunakan metode *nearest fill mode*.

Proses augmentasi dijalankan melalui algoritma perulangan untuk menjamin distribusi data yang seimbang (*perfectly balanced*). Melalui mekanisme ini, jumlah data latih setiap kelas ditingkatkan dari 160 citra menjadi 600 citra. Dengan demikian, total keseluruhan data latih meningkat secara signifikan dari 800 menjadi 3.000 citra. Visualisasi distribusi frekuensi data setelah augmentasi disajikan pada Gambar 3.




Gambar 3. Distribusi Frekuensi Data Latih Setelah Augmentasi

2.3. Model dan Skenario Pelatihan

Penelitian ini menerapkan pendekatan *transfer learning* dengan menggunakan model MobileNetV3-Large yang telah dilatih sebelumnya pada dataset ImageNet. Eksperimen ini diimplementasikan menggunakan pustaka (*library*) TensorFlow/Keras pada lingkungan komputasi yang diakselerasi oleh *Graphics Processing Unit* (GPU). Guna mencegah terjadinya kebocoran data (*data leakage*), pemisahan dataset menjadi subset data latih, validasi, dan uji dilakukan secara mutlak sebelum prosedur augmentasi dijalankan. Hal ini menjamin bahwa

model dievaluasi secara murni menggunakan data uji yang benar-benar belum pernah dilihat (*unseen data*) selama proses pelatihan. Model diinisialisasi sebagai *frozen base model* untuk ekstraksi fitur statis. Sebuah lapisan klasifikasi kustom (*custom classification head*) ditambahkan, yang meliputi lapisan *Global Average Pooling 2D*, lapisan *Dense* dengan 256 neuron (aktivasi ReLU), serta lapisan *Dropout* dengan laju 0,4 sebagai teknik regularisasi. Alur pelatihan model diilustrasikan pada Gambar 4.



Gambar 4. Alur Pelatihan Model MobileNetV3-Large

Pelatihan dikonfigurasi menggunakan *optimizer* Adam dengan *learning rate* awal sebesar 0,001, fungsi kerugian *categorical crossentropy*, dan *batch size* 16 selama maksimal 50 *epoch*. Optimasi dinamis diterapkan melalui dua mekanisme *callback*, yaitu *Early Stopping* (*patience* 10) dan *Learning Rate Scheduler*. Mekanisme *Learning Rate Scheduler* bekerja dengan menurunkan nilai *learning rate* secara eksponensial setelah *epoch* ke-10 untuk memastikan model mencapai titik konvergensi yang lebih halus dan presisi saat mendekati nilai optimal. Selain itu, pada skenario kedua, penjelasan mengenai pemilihan parameter augmentasi (seperti rotasi 20° dan *horizontal flip*) ditetapkan dengan alasan bahwa penyesuaian geometris tersebut merepresentasikan variabilitas alami dari posisi, sudut pandang, dan orientasi daun di lapangan saat difoto secara riil, tanpa merusak atau mengubah karakteristik pola fitur visual utama dari gejala penyakit. Ringkasan parameter disajikan pada Tabel 2.

Tabel 2. Ringkasan Parameter Pelatihan Model

Parameter	Konfigurasi Eksperimen
Model Dasar	MobileNetV3-Large
Ukuran Input Citra	224 x 224 x 3
Fungsi Aktivasi Tambahan	ReLU (Hidden Layer) & Softmax (Output Layer)
Optimizer	Adam
Loss Function	Categorical Crossentropy
Dropout Rate	0.4
Batch Size	16
Callbacks Optimasi	Early Stopping & Learning Rate Scheduler
Skenario Eksperimen	2 Skenario (Dataset Orisinal vs Augmentasi Data)

2.4. Evaluasi

Tahap evaluasi mengukur kemampuan generalisasi model MobileNetV3-Large menggunakan data uji. Metrik yang digunakan meliputi *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang dihitung berdasarkan Persamaan (1), (2), (3), dan (4) sebagai berikut:

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (3)$$

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

Dalam perhitungan tersebut, *True Positive* (TP) dan *True Negative* (TN) merepresentasikan data positif dan negatif yang diprediksi dengan benar oleh model. Sebaliknya, *False Positive* (FP) menunjukkan data negatif yang salah diprediksi sebagai positif, sementara *False Negative* (FN) adalah data positif yang salah diprediksi sebagai negatif. Selain metrik kuantitatif tersebut, penelitian ini juga menggunakan *confusion matrix* untuk memvisualisasikan distribusi prediksi antar kelas secara mendalam, sehingga memudahkan identifikasi kemiripan fitur visual yang berpotensi memicu kesalahan klasifikasi pada setiap jenis penyakit daun labu manis.


3. HASIL PENELITIAN DAN PEMBAHASAN


Bagian ini menyajikan hasil evaluasi performa klasifikasi MobileNetV3-Large pada dua skenario eksperimen, yaitu penggunaan dataset orisinal dan dataset hasil augmentasi. Kedua skenario dilatih menggunakan kombinasi *Early Stopping* (ES) dan *Learning Rate Scheduler* (LRS) untuk menjaga stabilitas proses pelatihan serta mengurangi risiko *overfitting*.

3.1. Proses Training

Pada skenario pertama, yaitu MobileNetV3-Large menggunakan dataset orisinal, hasil proses pelatihan ditunjukkan pada Gambar 6 sebelah atas. Model menunjukkan proses konvergensi yang relatif cepat dengan akurasi validasi mencapai 93%. Mekanisme *Early Stopping* menghentikan proses pelatihan secara otomatis pada epoch ke-16 setelah tidak ditemukan peningkatan performa yang signifikan pada data validasi. Hasil tersebut menunjukkan bahwa MobileNetV3-Large mampu mempelajari karakteristik utama dataset orisinal secara efektif dengan jumlah epoch yang relatif sedikit.

Pada skenario kedua, yaitu MobileNetV3-Large menggunakan dataset hasil augmentasi, hasil pelatihan ditunjukkan pada Gambar 5 sebelah bawah. Penambahan variasi data menyebabkan proses pelatihan berlangsung lebih lama dibandingkan skenario pertama. Model mencapai akurasi validasi sebesar 92% dan berhenti pada epoch ke-23 melalui mekanisme *Early Stopping*. Hasil ini menunjukkan bahwa kombinasi augmentasi data dan strategi optimasi mampu menjaga stabilitas pelatihan meskipun model dihadapkan pada variasi citra yang lebih kompleks.






Gambar 5. Grafik Acc-Loss MobileNetV3-Large (Dataset Orisinal) dan (Augmentasi Data)

3.2. Proses Testing

Evaluasi pada data uji dilakukan untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah digunakan pada proses pelatihan. Hasil pengujian menunjukkan adanya perbedaan performa antara penggunaan dataset orisinal dan dataset hasil augmentasi.

Pada skenario pertama yang menggunakan dataset orisinal dengan dukungan ES dan LRS, model menghasilkan akurasi sebesar 85,00%. Berdasarkan analisis *confusion matrix* pada Gambar 7 sebelah kiri, model mampu mengklasifikasikan kelas *Downy Mildew* dengan baik. Namun, beberapa kesalahan klasifikasi masih ditemukan pada kelas *Mosaic Disease* dan *Red Beetle*, yang menunjukkan adanya kemiripan pola visual antar kelas.

Pada skenario kedua yang menggunakan dataset hasil augmentasi dengan dukungan ES dan LRS, model menunjukkan peningkatan performa dengan akurasi sebesar 88,00%. Berdasarkan *confusion matrix* pada Gambar 6 sebelah kanan, model mampu mengklasifikasikan kelas *Healthy Leaf* secara sempurna dengan tingkat keberhasilan 100% (20/20). Hasil tersebut menunjukkan bahwa penambahan variasi data melalui augmentasi berkontribusi terhadap peningkatan kemampuan generalisasi model.



Gambar 6. Confusion Matrix MobileNetV3-Large (Dataset Orisinal) dan (Augmentasi Data)

Berdasarkan hasil pengujian pada kedua skenario, ringkasan metrik evaluasi ditunjukkan pada Tabel 3. Hasil tersebut menunjukkan bahwa penggunaan augmentasi data memberikan peningkatan pada nilai *Precision*, *Recall*, *Accuracy*, dan *F1-score* dibandingkan penggunaan dataset orisinal.

Tabel 3. Ringkasan Hasil Metrik Evaluasi MobileNetV3-Large

Kondisi Data	Precision	Recall	Accuracy	F1-score
Dataset Orisinal	86%	85%	85%	85%
Dataset Hasil Augmentasi	87%	87%	88%	87%

Selain performa klasifikasi, penelitian ini juga mengevaluasi efisiensi komputasi model untuk mengetahui potensi implementasi pada perangkat dengan sumber daya terbatas. Hasil pengukuran efisiensi komputasi ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan Efisiensi Komputasi MobileNetV3-Large

Kondisi Data	Test Accuracy	Waktu per Epoch (s)	Ukuran File (MB)
Dataset Orisinal	0.85	13	15
Dataset Hasil Augmentasi	0.88	37	15

Berdasarkan Tabel 4, penggunaan augmentasi data meningkatkan waktu pelatihan dari 13 detik menjadi 37 detik per epoch akibat bertambahnya jumlah data pelatihan. Meskipun demikian, ukuran model tetap sebesar 15 MB pada kedua skenario. Hasil tersebut menunjukkan bahwa MobileNetV3-Large mampu mempertahankan efisiensi ukuran model sekaligus meningkatkan akurasi klasifikasi melalui penerapan augmentasi data.

3.3. Pembahasan

Hasil eksperimen menunjukkan bahwa penerapan augmentasi data memberikan pengaruh positif terhadap performa klasifikasi penyakit daun labu manis menggunakan model MobileNetV3-Large. Pada skenario dataset orisinal, model menghasilkan akurasi pengujian sebesar 85,00% dengan nilai *precision*, *recall*, dan *F1-score* masing-masing sebesar 86%, 85%, dan 85%. Setelah dilakukan augmentasi data, performa klasifikasi pada model meningkat menjadi 88,00%, disertai peningkatan nilai *precision*, *recall*, dan *F1-score* menjadi 87%, 87%, dan 87%. Peningkatan akurasi sebesar 3% ini mengindikasikan bahwa model dasar MobileNetV3-Large yang memanfaatkan bobot praterlatih (*pre-trained weights*) dari ImageNet sebenarnya telah mampu mengekstraksi fitur visual yang cukup diskriminatif dan representatif sejak dari dataset orisinal. Faktor utama yang menyebabkan peningkatan akurasi bertahan di angka 3% adalah karakteristik citra pada dataset asli yang diambil dalam kondisi lingkungan relatif seragam dan terkontrol. Karena variasi latar belakang dan pencahayaan pada data asli minim, arsitektur dasar model sudah dapat mencapai posisi pemahaman fitur yang tinggi di awal pelatihan. Dengan demikian, penerapan augmentasi geometris (rotasi dan *flipping*) dalam penelitian ini tidak merombak kemampuan ekstraksi fitur secara drastis, melainkan berfokus pada penguatan batas keputusan (*decision boundary*) model agar lebih tahan (*robust*) terhadap variasi sudut pandang pada data uji [11].

Selain meningkatkan performa klasifikasi, penggunaan kombinasi *Early Stopping* dan *Learning Rate Scheduler* juga berkontribusi terhadap stabilitas proses pelatihan. Pada skenario dataset orisinal, model mencapai titik konvergensi pada epoch ke-16 dengan akurasi validasi sebesar 93%, sedangkan pada skenario augmentasi model berhenti pada epoch ke-23 dengan akurasi validasi sebesar 92%. Perbedaan jumlah epoch tersebut menunjukkan bahwa penambahan variasi data menyebabkan model membutuhkan waktu pelatihan yang lebih panjang untuk mempelajari distribusi fitur yang lebih kompleks. Namun, mekanisme optimasi yang digunakan mampu menjaga kestabilan proses pelatihan dan mencegah terjadinya *overfitting* [16], [17].

Untuk mengevaluasi efektivitas model yang diusulkan, hasil penelitian ini dibandingkan dengan beberapa penelitian terdahulu yang menggunakan objek serupa, yaitu klasifikasi penyakit daun labu manis, sebagaimana ditunjukkan pada Tabel 5.

Tabel 5. Perbandingan dengan Penelitian Terdahulu

Referensi	Metode	Objek	Akurasi
Khaldi & Kalmoun [1]	DenseNet-121	Daun Labu Manis	86,00%
Biswas <i>et al.</i> [5]	DenseNet-121	Daun Labu Manis	97,82%
Khandaker <i>et al.</i> [18]	ResNet50	Daun Labu Manis	90,50%
Bezabh <i>et al.</i> [20]	Hybrid CNN	Daun Labu Manis	96,00%
Model usulan (original)	MobileNetV3-Large	Daun Labu Manis	85,00%
Model usulan (augmentasi)	MobileNetV3-Large	Daun Labu Manis	88,00%

Berdasarkan Tabel 5, model yang diusulkan pada skenario augmentasi berhasil mencapai akurasi sebesar 88,00%, menunjukkan performa yang kompetitif dibanding penelitian Khaldi dan Kalmoun yang menggunakan DenseNet121 dengan akurasi 86,00% [1]. Hasil ini menunjukkan bahwa model MobileNetV3-Large yang memiliki kompleksitas lebih rendah tetap mampu memberikan performa yang kompetitif pada objek klasifikasi yang sama.

Meskipun akurasi model yang diusulkan masih berada di bawah penelitian Biswas *et al.* yang mencapai 97,82% menggunakan DenseNet121 [5], Khandaker *et al.* yang memperoleh akurasi 90,50% menggunakan ResNet50 [18], serta Bezabh *et al.* yang mencapai 96,00% menggunakan *Hybrid CNN* [20], model yang diusulkan memiliki keunggulan pada aspek efisiensi komputasi. Pada kedua skenario, ukuran model tetap sebesar 15 MB, sehingga jauh lebih ringan untuk diterapkan pada perangkat *mobile* maupun *edge computing*. Karakteristik tersebut sesuai dengan desain MobileNetV3 yang memanfaatkan mekanisme *depthwise separable convolution* untuk menurunkan jumlah parameter tanpa mengurangi kemampuan ekstraksi fitur secara signifikan [13].

Peningkatan akurasi dari 85,00% menjadi 88,00% setelah penerapan augmentasi data menunjukkan bahwa kualitas dan keberagaman dataset memiliki pengaruh langsung terhadap performa klasifikasi. Hasil ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa augmentasi data mampu meningkatkan kemampuan generalisasi model serta mengurangi risiko *overfitting* pada dataset dengan jumlah sampel terbatas [10], [11].

Secara keseluruhan, hasil penelitian menunjukkan bahwa kombinasi MobileNetV3-Large, augmentasi data, *Early Stopping*, dan *Learning Rate Scheduler* mampu menghasilkan keseimbangan antara performa klasifikasi dan efisiensi komputasi. Dengan akurasi sebesar 88,00% dan ukuran model hanya 15 MB, pendekatan yang diusulkan memiliki potensi implementasi yang baik pada sistem deteksi penyakit tanaman berbasis perangkat bergerak untuk mendukung kegiatan pertanian cerdas.

Meskipun hasil yang diperoleh menunjukkan performa yang cukup baik, penelitian ini masih memiliki keterbatasan pada jumlah dataset yang relatif terbatas dan penggunaan citra yang diperoleh pada kondisi lingkungan terkontrol, sehingga evaluasi pada kondisi lapangan nyata masih diperlukan.

4. KESIMPULAN

Penelitian ini berhasil menganalisis pengaruh penerapan augmentasi data terhadap performa klasifikasi penyakit daun labu manis menggunakan model MobileNetV3-Large dengan dukungan teknik optimasi *Early Stopping* dan *Learning Rate Scheduler*. Hasil eksperimen

menunjukkan bahwa penggunaan dataset orisinal menghasilkan akurasi sebesar 85,00%, dengan nilai *precision* sebesar 86%, *recall* sebesar 85%, dan *F1-score* sebesar 85%. Setelah diterapkan augmentasi data, performa klasifikasi pada model mengalami peningkatan dengan akurasi mencapai 88,00%, serta nilai *precision*, *recall*, dan *F1-score* masing-masing sebesar 87%.

Selain meningkatkan performa klasifikasi, penerapan augmentasi data juga terbukti meningkatkan kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Dari sisi efisiensi komputasi, MobileNetV3-Large mampu mempertahankan ukuran model yang tetap ringan, yaitu sebesar 15 MB pada kedua skenario. Karakteristik ukuran model yang relatif kecil menunjukkan potensi untuk pengembangan lebih lanjut pada perangkat *mobile* maupun *edge computing*, namun pengujian *deployment* pada perangkat nyata masih diperlukan.

Berdasarkan hasil tersebut, kombinasi MobileNetV3-Large, augmentasi data, *Early Stopping*, dan *Learning Rate Scheduler* dapat menjadi pendekatan yang efektif dalam pengembangan sistem deteksi penyakit daun labu manis secara otomatis dengan mempertimbangkan keseimbangan antara akurasi klasifikasi dan efisiensi komputasi.

Untuk penelitian selanjutnya, pengembangan dapat dilakukan dengan menambahkan jumlah dataset, memperluas variasi kelas penyakit, serta mengevaluasi performa klasifikasi pada model di kondisi citra lapangan secara *real-time* guna meningkatkan ketahanan model dan kesiapan implementasi pada lingkungan pertanian nyata.

DAFTAR PUSTAKA

- [1] A. Khaldi and E. M. Kalmoun, "Automated Disease Diagnosis in Pumpkin Plants Using Advanced CNN Models," *IEEE Access*, vol. 12, pp. 24501–24512, 2024.
- [2] A. B. Ayyappan and T. G. M. Kumar, "Rice Plant Disease Detection using Convolutional Neural Networks," *Discov. Artif. Intell.*, vol. 5, no. 1, p. 12, 2025.
- [3] T. H. Pinem and Z. P. Putra, "Evaluasi Kinerja Algoritma Klasifikasi Deep Learning dalam Prediksi Diabetes," *J. Ilm. FIFO*, vol. 17, no. 1, pp. 17–28, 2025.
- [4] X. Z. W. Feng, Q. Song, G. Sun, "Lightweight Isotropic Convolutional Neural Network for Plant," *Agronomy*, vol. 13, no. 7, p. 1849, 2023.
- [5] J. Biswas *et al.*, "Pumpkin Leaf Disease Classification: A Comparative Study of SimCLR and Traditional Supervised Learning Approaches," in *2025 International Conference on Quantum Photonics, Artificial Intelligence, and Networking (QPAIN)*, 2025, pp. 1–6.
- [6] M. Daffa, A. Putra, T. S. Winanto, R. Hendrowati, and A. Primajaya, "A Comparative Analysis of Transfer Learning Architecture Performance on Convolutional Neural Network Models with Diverse Datasets," *J. Comput. Sci. Technol.*, vol. 12, no. 1, pp. 1–11, 2023.
- [7] M. Jung *et al.*, "Construction of deep learning - based disease detection model in plants," *Sci. Rep.*, vol. 13, no. 1, p. 7331, 2023.
- [8] M. Sholihin, M. F. Fudzee, and L. Anifah, "A Novel CNN-Based Approach for Classification of Tomato Plant Diseases," *J. Appl. Artif. Intell.*, vol. 24, no. 3, pp. 465–478, 2025.
- [9] M. Sholihin, M. R. Zamroni, L. Anifah, and M. F. Fudzee, "Fine-Tuned Transfer Learning with InceptionV3 for Automated Detection of Grapevine Leaf Diseases," *J. Agric. Eng.*, vol. 6, no. 5, pp. 3683–3696, 2025.
- [10] K. Antwi, K. Ebo, D. Kwaku, P. Asiedu, and B. Tekinerdogan, "On the application of image augmentation for plant disease detection : A systematic literature review," *Smart Agric. Technol.*, vol. 9, p. 100590, 2024.
- [11] I. I. A. Agustina, F. Yanto, E. Budianita, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode CNN Arsitektur DenseNet-121 dan Augmentasi Data," *JOISIE*

- (*Journal Inf. Syst. Informatics Eng.*, vol. 8, no. 1, pp. 124–134, 2024.
- [12] B. Baso and R. M. Akhyar, “Analisis Pengaruh Data Augmentasi Pada Klasifikasi Tenun Menggunakan Deep Learning Berbasis Convolutional Neural Network Analysis of the Effect of Data Augmentation on Weaving Classification Using Deep Learning Based on Convolutional Neural Network,” *J. Ilmu Tek. dan Komput.*, vol. 5, no. 1, pp. 20–24, 2025.
 - [13] A. T. Khan, S. M. Jensen, A. R. Khan, and S. Li, “Plant disease detection model for edge computing devices,” *Front. Plant Sci.*, vol. 14, p. 1308528, 2023.
 - [14] C. Bi, S. Xu, N. Hu, S. Zhang, Z. Zhu, and H. Yu, “Identification Method of Corn Leaf Disease Based on Improved Mobilenetv3 Model,” *Agronomy*, vol. 13, no. 2, p. 300, 2023.
 - [15] X. Yin, W. Li, Z. Li, and L. Yi, “Recognition of grape leaf diseases using MobileNetV3 and deep transfer learning,” *Int. J. Agric. Biol. Eng.*, vol. 15, no. 3, pp. 184–194, 2022.
 - [16] M. S. Alzahrani, “Transform and Deep Learning Algorithms for the Early Detection and Recognition of Tomato Leaf Disease,” *Agronomy*, vol. 13, no. 5, p. 1184, 2023.
 - [17] V. Pandiyaraju, A. M. S. Kumar, J. I. R. Praveen, S. Venkatraman, S. P. Kumar, and S. A. Aravindakshan, “Improved tomato leaf disease classification through adaptive ensemble models with exponential moving average fusion and enhanced weighted gradient optimization,” *Front. Plant Sci.*, vol. 15, p. 1382416, 2024.
 - [18] A. A. Khandaker, Z. S. Raha, S. Islam, and T. Muhammad, “Explainable AI-Enhanced Deep Learning for Pumpkin Leaf Disease Detection : A Comparative Analysis of CNN Architectures,” in *2024 27th International Conference on Computer and Information Technology (ICCIT)*, 2024, no. December, pp. 20–22.
 - [19] M. M. H. M. M. A. Khasru, “Sweet Pumpkin Disease Recognition Dataset,” 2024. [Online]. Available: <https://data.mendeley.com/datasets/7397w9h5tb>.
 - [20] Y. A. Bezabh, B. M. Abuhayi, and A. M. Ayalew, “Classification of pumpkin disease by using a hybrid approach,” *Smart Agric. Technol.*, vol. 7, p. 100398, 2024.