

Analisa Komparatif MobileNetV2 dan EfficientNetB0 Berbasis *Fine-Tuning* dan *Data Augmentation* untuk Klasifikasi Penyakit Daun Pisang

Wadzifa^{1*}, Deasy Purwaningias², Ali Mustopa³

^{1,2,3}Fakultas Teknik dan Informatika, Program Studi Informatika, Universitas Bina Sarana Informatika, Kota Pontianak, Indonesia

Email: ^{1*}15220472@bsi.ac.id, ²deasy.dwg@bsi.ac.id, ³alimustopa.aop@bsi.ac.id

(*Email Corresponding Author: 15220472@bsi.ac.id)

Received: 25 Juni 2026 | Revision: 29 Juni 2026 | Accepted: 2 Juli 2026

Abstrak

Penyakit daun pisang merupakan salah satu faktor yang dapat menurunkan produktivitas tanaman pisang dan menyebabkan kerugian ekonomi bagi petani. Identifikasi penyakit secara manual memerlukan waktu serta bergantung pada keahlian pengamat, sehingga diperlukan sistem otomatis yang mampu melakukan klasifikasi penyakit secara cepat dan akurat. Penelitian ini bertujuan menganalisis performa model *transfer learning* MobileNetV2 dan EfficientNetB0 dalam klasifikasi penyakit daun pisang menggunakan dataset BananaLSD yang terdiri atas empat kelas, yaitu *Healthy*, *Cordana*, *Pestalotiopsis*, dan *Sigatoka*. Penelitian dilakukan melalui delapan skenario eksperimen yang mengombinasikan penerapan *fine-tuning* dan *data augmentation* untuk mengetahui pengaruhnya terhadap performa model. Model terbaik selanjutnya dibandingkan menggunakan empat *optimizer*, yaitu Adam, AdamW, RMSprop, dan SGD. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix*. Hasil penelitian menunjukkan bahwa kombinasi EfficientNetB0 dengan *fine-tuning*, *data augmentation*, dan *optimizer* Adam menghasilkan performa terbaik dengan nilai *accuracy* sebesar 97,89%, *precision* 98,58%, *recall* 97,89%, dan *F1-score* 98,00%. Model terbaik kemudian diimplementasikan menggunakan FastAPI dan diintegrasikan dengan aplikasi bergerak berbasis FlutterFlow sehingga mampu melakukan klasifikasi penyakit daun pisang secara *real-time*. Hasil penelitian menunjukkan bahwa kombinasi arsitektur, strategi pelatihan, dan *optimizer* yang tepat mampu meningkatkan performa klasifikasi serta menghasilkan prototipe aplikasi yang dapat mendukung identifikasi awal penyakit daun pisang secara cepat, akurat, dan mudah digunakan.

Kata Kunci: Penyakit Daun Pisang, *Transfer Learning*, MobileNetV2, EfficientNetB0, *Fine-Tuning*, *Data Augmentation*

Abstract

Banana leaf diseases are one of the major factors that reduce banana productivity and cause economic losses to farmers. Manual disease identification is time-consuming and highly dependent on the expertise of observers, creating the need for an automated system capable of providing fast and accurate disease classification. This study aims to analyze the performance of the MobileNetV2 and EfficientNetB0 transfer learning models for banana leaf disease classification using the BananaLSD dataset, which consists of four classes: *Healthy*, *Cordana*, *Pestalotiopsis*, and *Sigatoka*. The study employed eight experimental scenarios combining *fine-tuning* and *data augmentation* to evaluate their effects on model performance. The best-performing model was subsequently compared using four optimization algorithms, namely Adam, AdamW, RMSprop, and SGD. Model performance was evaluated using *accuracy*, *precision*, *recall*, *F1-score*, and *confusion matrix metrics*. The experimental results show that the combination of EfficientNetB0 with *fine-tuning*, *data augmentation*, and the Adam optimizer achieved the best performance, obtaining 97.89% accuracy, 98.58% precision, 97.89% recall, and 98.00% F1-score. The best model was implemented using FastAPI and integrated into a FlutterFlow-based mobile application, enabling real-time banana leaf disease classification on mobile devices. The proposed approach demonstrates that the appropriate combination of network architecture, training strategy, and optimization algorithm can improve classification performance while providing a practical prototype for rapid, accurate, and user-friendly early detection of banana leaf diseases.

Keywords: Banana Leaf Disease, *Transfer Learning*, MobileNetV2, EfficientNetB0, *Fine-Tuning*, *Data Augmentation*

1. PENDAHULUAN

Besarnya produksi pisang di Indonesia menunjukkan bahwa komoditas ini memiliki peran penting dalam mendukung sektor hortikultura nasional. Berdasarkan Statistik Hortikultura 2025 yang diterbitkan oleh Badan Pusat Statistik, produksi pisang nasional mencapai 9,82 juta ton pada tahun 2025 atau meningkat sebesar 6,02% dibandingkan tahun sebelumnya. Tingginya tingkat produksi tersebut menunjukkan bahwa upaya menjaga kesehatan tanaman menjadi faktor penting dalam mempertahankan produktivitas dan kualitas hasil panen [1]. Namun, tanaman pisang masih rentan terhadap berbagai penyakit daun, seperti *Cordana*, *Pestalotiopsis*, dan *Sigatoka*, yang dapat mengganggu proses fotosintesis sehingga dapat menurunkan pertumbuhan tanaman dan hasil produksi. Selain itu, kemiripan gejala visual pada beberapa jenis penyakit menyebabkan proses identifikasi secara manual sering kali memerlukan keahlian khusus

dan berpotensi menghasilkan diagnosis yang kurang akurat [2]. Perkembangan teknologi *deep learning* membuka peluang dalam pengembangan sistem identifikasi penyakit tanaman secara otomatis melalui analisis citra digital sehingga dapat meningkatkan kecepatan dan ketepatan proses diagnosis. Salah satu dataset publik yang banyak dimanfaatkan dalam pengembangan model klasifikasi penyakit daun pisang adalah BananaLSD, yang menyediakan citra daun sehat maupun terinfeksi berbagai jenis penyakit sebagai data pelatihan dan pengujian model berbasis *machine learning* maupun *deep learning* [3].

Perkembangan teknologi *computer vision* telah mendorong penerapan pendekatan identifikasi penyakit tanaman dari metode berbasis pengamatan visual menuju analisis citra digital secara otomatis. Transformasi tersebut didukung oleh kemajuan *deep learning* yang mampu mempelajari representasi fitur secara mandiri sehingga memberikan kinerja klasifikasi yang lebih baik [4]. Dalam perkembangannya, pemanfaatan *transfer learning* menjadi salah satu strategi yang banyak diterapkan karena mampu mempercepat proses pelatihan sekaligus tetap menghasilkan akurasi yang baik pada dataset berukuran terbatas [5]. Kondisi tersebut mendorong semakin luasnya penerapan model *deep learning* dalam pengembangan sistem deteksi penyakit tanaman berbasis citra digital yang mampu mendukung proses diagnosis secara lebih akurat, efisien, dan adaptif terhadap kebutuhan sektor pertanian modern [6].

Berbagai penelitian telah menerapkan pendekatan *deep learning* untuk klasifikasi penyakit daun pisang dan menunjukkan hasil yang menjanjikan. Penerapan *Convolutional Neural Network* (CNN) berbasis *transfer learning* dilaporkan mampu mencapai akurasi sebesar 92% pada proses identifikasi penyakit daun pisang [7]. Seiring dengan perkembangan arsitektur *deep learning*, MobileNetV2 mulai banyak diterapkan pada klasifikasi penyakit daun pisang karena menawarkan keseimbangan antara akurasi dan efisiensi komputasi, dengan capaian akurasi sebesar 90,62% pada klasifikasi empat kelas penyakit daun pisang [8]. Penelitian lain menunjukkan bahwa penerapan CNN yang dipadukan dengan augmentasi citra mampu meningkatkan akurasi hingga 92,85% [9]. Selain itu, penelitian yang membandingkan MobileNetV2 dan EfficientNetB0 pada klasifikasi jenis pisang menunjukkan bahwa EfficientNetB0 memperoleh akurasi sebesar 80%, lebih tinggi dibandingkan MobileNetV2 yang mencapai 75% [10]. Pada penelitian lain, MobileNetV2 juga dilaporkan menghasilkan akurasi sebesar 96,21% dengan ukuran model yang lebih ringan dibandingkan VGG16 pada klasifikasi penyakit daun pisang [11]. Berbagai hasil penelitian tersebut menunjukkan bahwa performa model sangat dipengaruhi oleh pemilihan arsitektur serta strategi pelatihan yang digunakan. Oleh karena itu, evaluasi terhadap berbagai arsitektur *deep learning* masih diperlukan untuk memperoleh model dengan kinerja yang lebih optimal pada klasifikasi penyakit daun pisang.

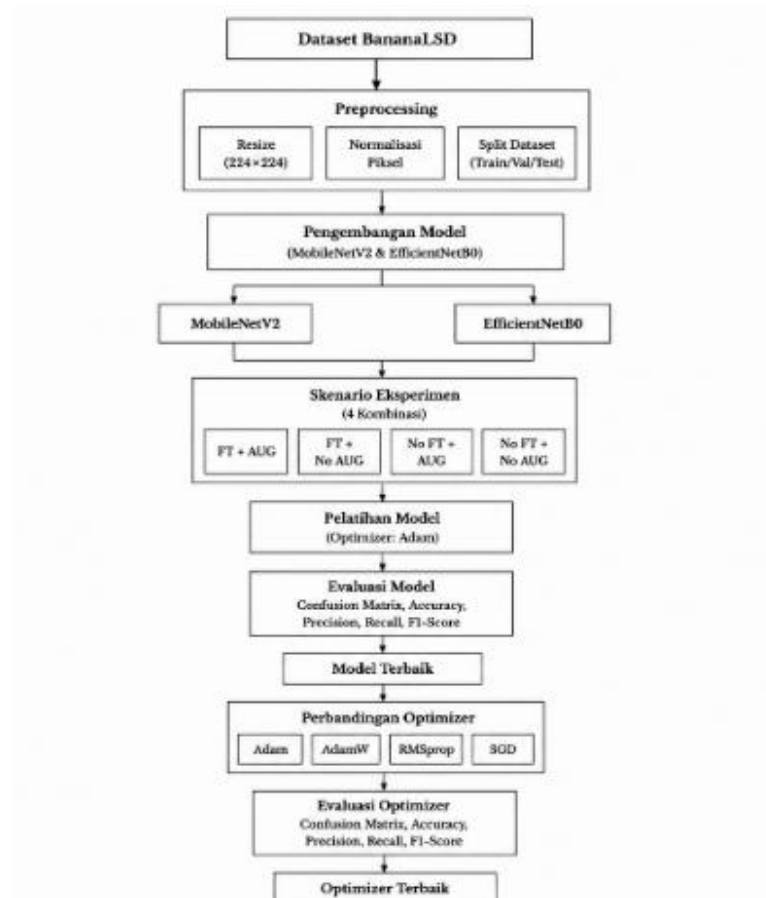
Meskipun berbagai penelitian terdahulu telah menunjukkan hasil yang baik dalam klasifikasi penyakit daun pisang, kajian yang secara khusus membandingkan MobileNetV2 dan EfficientNetB0 pada klasifikasi penyakit daun pisang masih terbatas, terutama yang mengombinasikan strategi *fine-tuning* dan *data augmentation* dalam evaluasi kedua arsitektur tersebut. Padahal, *fine-tuning* memungkinkan model pralatih beradaptasi lebih optimal terhadap karakteristik dataset yang digunakan sehingga mampu meningkatkan performa klasifikasi [12]. Selain itu, penerapan *data augmentation* juga terbukti dapat memperkaya variasi data pelatihan serta meningkatkan kemampuan generalisasi model terhadap data baru [13]. Oleh karena itu, penelitian ini melakukan perbandingan performa MobileNetV2 dan EfficientNetB0 menggunakan pendekatan *fine-tuning* dan *data augmentation* pada dataset BananaLSD untuk mengidentifikasi arsitektur yang memberikan performa klasifikasi terbaik pada penyakit daun pisang.

Berdasarkan latar belakang, penelitian terdahulu, dan *research gap* yang telah diuraikan, penelitian ini bertujuan untuk membandingkan performa arsitektur MobileNetV2 dan EfficientNetB0 pada klasifikasi penyakit daun pisang melalui empat skenario pelatihan yang mengombinasikan penerapan *fine-tuning* dan *data augmentation* pada dataset BananaLSD. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengidentifikasi model dengan performa terbaik. Selanjutnya, model terbaik dievaluasi kembali menggunakan beberapa *optimizer*, yaitu Adam, AdamW, RMSprop, dan SGD, guna memperoleh konfigurasi pelatihan yang paling optimal. Model dengan hasil terbaik kemudian diimplementasikan ke dalam layanan *Application Programming Interface* (API) berbasis FastAPI dan diintegrasikan dengan aplikasi yang dikembangkan menggunakan FlutterFlow sebagai prototipe sistem deteksi penyakit daun pisang. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem klasifikasi penyakit tanaman yang akurat, efisien, dan siap diimplementasikan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan penelitian yang dilakukan pada penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

Penelitian diawali dengan penggunaan dataset BananaLSD yang terdiri atas citra daun pisang sehat dan terinfeksi berbagai jenis penyakit. Selanjutnya dilakukan tahap *preprocessing* yang meliputi *resize* citra menjadi 224×224 piksel, normalisasi nilai piksel, serta pembagian *dataset* ke dalam data pelatihan, data validasi, dan data pengujian. Tahap berikutnya adalah pengembangan model menggunakan dua arsitektur *deep learning*, yaitu MobileNetV2 dan EfficientNetB0. Masing-masing arsitektur kemudian diuji menggunakan empat kombinasi skenario yang melibatkan penerapan *fine-tuning* dan *data augmentation* sehingga diperoleh delapan skenario eksperimen.

Setiap skenario eksperimen selanjutnya dilatih menggunakan *optimizer Adam* dan dievaluasi berdasarkan metrik *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix* untuk menentukan model dengan performa terbaik. Model terbaik yang diperoleh kemudian digunakan pada tahap perbandingan *optimizer* yang melibatkan Adam, AdamW, RMSprop, dan SGD guna memperoleh konfigurasi pelatihan yang menghasilkan kinerja paling optimal. Tahap akhir penelitian adalah mengimplementasikan model terbaik beserta *optimizer* terbaik ke dalam layanan *Application Programming Interface* (API) menggunakan FastAPI yang diintegrasikan dengan aplikasi berbasis FlutterFlow sebagai prototipe sistem klasifikasi penyakit daun pisang.

2.2 Dataset

Penelitian ini menggunakan *Original Set* dari dataset BananaLSD yang terdiri atas citra daun pisang sehat (*Healthy*) dan tiga jenis penyakit daun pisang, yaitu *Cordana*, *Pestalotiopsis*, dan *Sigatoka*. Dataset tersebut berisi citra RGB yang telah diberi label sesuai kategori penyakit dan digunakan sebagai data utama pada penelitian ini. Distribusi jumlah citra pada setiap kelas ditunjukkan pada Tabel 1.

Tabel 1. Distribusi *Dataset*

Kelas	Jumlah Citra
<i>Healthy</i>	129
<i>Cordana</i>	162
<i>Pestalotiopsis</i>	173
<i>Sigatoka</i>	473
Total	937

Berdasarkan Tabel 1, kelas *Sigatoka* memiliki jumlah citra terbanyak, sedangkan kelas *Healthy* memiliki jumlah citra paling sedikit. Karakteristik distribusi tersebut menjadi dasar dalam proses pengembangan dan evaluasi model klasifikasi pada penelitian ini.

2.3 Preprocessing

Tahap *preprocessing* dilakukan untuk menyeragamkan data masukan sebelum digunakan pada proses pengembangan model. Tahapan ini meliputi *resize* citra menjadi 224×224 piksel, normalisasi menggunakan fungsi *preprocess_input* sesuai kebutuhan model *transfer learning* [14], serta pembagian *dataset* menjadi data pelatihan, validasi, dan pengujian dengan rasio 70:15:15.

Tabel 2. Pembagian *Dataset*

Jenis Data	Jumlah Citra	Persentase
<i>Training</i>	655	70%
<i>Validation</i>	140	15%
<i>Testing</i>	142	15%
Total	937	100%

Dataset yang telah melalui tahap proses *preprocessing* selanjutnya digunakan sebagai masukan pada proses pengembangan model.

2.4 Pengembangan Model

Pengembangan model dilakukan menggunakan pendekatan *transfer learning* [15] dengan dua arsitektur *Convolutional Neural Network* (CNN), yaitu MobileNetV2 dan EfficientNetB0. Kedua model menggunakan bobot awal (*pre-trained weights*) dari *ImageNet* sehingga proses pelatihan dapat dilakukan tanpa membangun model dari awal. Penggunaan kedua arsitektur tersebut bertujuan membandingkan performa model dalam mengklasifikasikan penyakit daun pisang. Kedua arsitektur selanjutnya diuji menggunakan skenario eksperimen yang sama.

2.5 Skenario Eksperimen

Setiap arsitektur model diuji menggunakan empat kombinasi skenario eksperimen yang melibatkan penerapan *fine-tuning* dan *data augmentation* [16]. Kombinasi tersebut terdiri atas model dengan *fine-tuning* dan *augmentation*, *fine-tuning* tanpa *augmentation*, tanpa *fine-tuning* dengan *augmentation*, serta tanpa *fine-tuning* dan tanpa *augmentation*. Dengan dua arsitektur yang digunakan, penelitian ini menghasilkan total delapan skenario eksperimen.

Tabel 3. Skenario Eksperimen

Model	Skenario
MobileNetV2	FT + AUG
MobileNetV2	FT + No AUG
MobileNetV2	No FT + AUG
MobileNetV2	No FT + No AUG
EfficientNetB0	FT + AUG
EfficientNetB0	FT + No AUG
EfficientNetB0	No FT + AUG
EfficientNetB0	No FT + No AUG

Seluruh skenario eksperimen kemudian memasuki tahap pelatihan menggunakan konfigurasi parameter yang sama agar hasil yang diperoleh dapat dibandingkan secara objektif.

2.6 Pelatihan Model

Tahap pelatihan dilakukan menggunakan *optimizer* Adam [17] dengan konfigurasi *hyperparameter* yang sama pada seluruh skenario eksperimen. Proses pelatihan menggunakan data pelatihan dan dipantau melalui data validasi hingga diperoleh bobot model terbaik pada masing-masing skenario. Model yang telah selesai dilatih selanjutnya dievaluasi untuk mengetahui performa klasifikasi pada data pengujian.

2.7 Evaluasi Model

Evaluasi model dilakukan menggunakan confusion matrix sebagai dasar perhitungan nilai *accuracy*, *precision*, *recall*, dan *F1-score* [18]. Metrik evaluasi tersebut digunakan untuk mengukur kemampuan model dalam mengklasifikasikan setiap kelas penyakit daun pisang serta membandingkan performa seluruh skenario eksperimen

sehingga diperoleh model dengan hasil klasifikasi terbaik. Nilai *accuracy*, *precision*, *recall*, dan *F1-score* dihitung menggunakan Persamaan (1)–(4).

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

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

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

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

Model dengan performa terbaik selanjutnya digunakan pada tahap perbandingan optimizer.

2.8 Perbandingan Optimizer

Model terbaik yang diperoleh pada tahap sebelumnya digunakan untuk membandingkan empat algoritma optimasi, yaitu Adam, AdamW, RMSprop, dan SGD [19]. Seluruh *optimizer* diterapkan menggunakan model, dataset, dan konfigurasi pelatihan yang sama sehingga hasil evaluasi dapat dibandingkan secara objektif. *Optimizer* dengan performa terbaik selanjutnya digunakan pada tahap implementasi sistem.

3. HASIL DAN PEMBAHASAN

3.1 Pengaruh *Fine-Tuning* dan *Data Augmentation* terhadap Performa Model

Pengujian dilakukan untuk menganalisis pengaruh penerapan *fine-tuning* dan *data augmentation* terhadap performa klasifikasi penyakit daun pisang menggunakan dua arsitektur *Convolutional Neural Network* (CNN), yaitu MobileNetV2 dan EfficientNetB0. Kedua arsitektur dipilih karena memiliki karakteristik yang berbeda dalam proses ekstraksi fitur. MobileNetV2 dirancang sebagai model ringan dengan jumlah parameter yang relatif sedikit sehingga memiliki efisiensi komputasi yang tinggi, sedangkan EfficientNetB0 menerapkan metode *compound scaling* yang mampu meningkatkan akurasi tanpa menambah kompleksitas model secara berlebihan. Perbedaan karakteristik tersebut menjadi dasar untuk membandingkan kemampuan masing-masing arsitektur dalam mengenali pola penyakit pada citra daun pisang.

Setiap arsitektur diuji menggunakan empat kombinasi skenario, yaitu tanpa *fine-tuning* dan tanpa *data augmentation*, tanpa *fine-tuning* dengan *data augmentation*, *fine-tuning* tanpa *data augmentation*, serta *fine-tuning* dengan *data augmentation*. Seluruh skenario menggunakan konfigurasi pelatihan yang sama, meliputi ukuran citra 224×224 piksel, *optimizer* Adam, jumlah *epoch*, serta pembagian dataset yang identik. Penyamaan konfigurasi pelatihan dilakukan agar perbedaan performa yang diperoleh benar-benar dipengaruhi oleh kombinasi strategi pelatihan yang diterapkan, sehingga proses evaluasi dapat dilakukan secara objektif.

Evaluasi terhadap setiap skenario dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Keempat metrik tersebut dipilih karena mampu memberikan gambaran yang lebih komprehensif mengenai kualitas model dibandingkan hanya menggunakan nilai *accuracy*. Nilai *accuracy* menunjukkan proporsi prediksi yang benar terhadap seluruh data pengujian, sedangkan *precision* menggambarkan ketepatan model dalam memberikan prediksi pada setiap kelas. Sementara itu, *recall* menunjukkan kemampuan model dalam mengenali seluruh data yang benar pada masing-masing kelas, sedangkan *F1-score* digunakan sebagai ukuran keseimbangan antara *precision* dan *recall*. Penggunaan keempat metrik tersebut menjadi penting karena dataset BananaLSD memiliki distribusi jumlah citra yang tidak seimbang pada setiap kelas. Hasil pengujian seluruh skenario ditunjukkan pada Tabel 4.

Tabel 4. Hasil Pengujian Delapan Skenario Model

No	Arsitektur	<i>Fine-Tuning</i>	<i>Data Augmentation</i>	<i>Accuracy</i> (%)	<i>Precision</i> (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)
1	MobileNetV2	Tidak	Tidak	97,18	97,18	97,18	97,00
2	MobileNetV2	Tidak	Ya	95,07	96,43	95,07	95,00
3	MobileNetV2	Ya	Tidak	97,18	97,16	96,48	97,00
4	MobileNetV2	Ya	Ya	96,48	96,48	96,48	96,00
5	EfficientNetB0	Tidak	Tidak	96,48	96,48	96,48	96,00
6	EfficientNetB0	Tidak	Ya	97,18	97,16	96,48	97,00
7	EfficientNetB0	Ya	Tidak	95,77	96,45	95,77	96,00
8	EfficientNetB0	Ya	Ya	97,89	98,58	97,89	98,00

Berdasarkan Tabel 4, seluruh skenario menghasilkan nilai *accuracy* di atas 95%, sehingga menunjukkan bahwa kedua arsitektur memiliki kemampuan yang baik dalam mengklasifikasikan penyakit daun pisang. Meskipun demikian, kombinasi penerapan *fine-tuning* dan *data augmentation* memberikan pengaruh yang berbeda terhadap performa masing-masing model. Perbedaan tersebut terlihat dari variasi nilai *accuracy*, *precision*, *recall*, maupun *F1-score* pada setiap skenario pengujian. Hasil ini menunjukkan bahwa efektivitas suatu strategi pelatihan sangat dipengaruhi oleh karakteristik arsitektur yang digunakan.

Pada arsitektur MobileNetV2, skenario tanpa *fine-tuning* dan tanpa *data augmentation* menghasilkan nilai *accuracy* sebesar 97,18%, sedangkan penerapan *fine-tuning* tanpa *data augmentation* menghasilkan nilai *accuracy* yang sama. Kondisi tersebut menunjukkan bahwa proses *fine-tuning* belum memberikan peningkatan performa yang signifikan pada MobileNetV2. Di sisi lain, ketika *data augmentation* diterapkan, nilai *accuracy* justru mengalami penurunan menjadi 95,07% pada skenario tanpa *fine-tuning* dan 96,48% pada skenario dengan *fine-tuning*. Hasil tersebut mengindikasikan bahwa variasi citra hasil augmentasi belum mampu meningkatkan kemampuan MobileNetV2 dalam mengenali karakteristik penyakit daun pisang pada konfigurasi pelatihan yang digunakan.

Berbeda dengan MobileNetV2, arsitektur EfficientNetB0 menunjukkan respons yang lebih baik terhadap penerapan *fine-tuning* dan *data augmentation*. Skenario dengan kombinasi kedua teknik tersebut menghasilkan nilai *accuracy* sebesar 97,89%, *precision* sebesar 98,58%, *recall* sebesar 97,89%, dan *F1-score* sebesar 98,00%, yang merupakan nilai tertinggi di antara seluruh skenario pengujian. Peningkatan tersebut menunjukkan bahwa EfficientNetB0 mampu memanfaatkan proses penyesuaian bobot (*fine-tuning*) secara lebih optimal sehingga fitur-fitur yang dipelajari menjadi lebih sesuai dengan karakteristik dataset BananaLSD. Selain itu, *data augmentation* memberikan variasi citra yang membantu model mempelajari berbagai kemungkinan perubahan posisi, orientasi, maupun bentuk daun sehingga kemampuan generalisasi model menjadi lebih baik.

Jika dibandingkan secara keseluruhan, EfficientNetB0 menunjukkan performa yang lebih konsisten dibandingkan MobileNetV2 pada hampir seluruh metrik evaluasi. Hal ini tidak hanya terlihat dari nilai *accuracy* yang lebih tinggi, tetapi juga dari peningkatan *precision*, *recall*, dan *F1-score* yang menunjukkan keseimbangan kemampuan model dalam mengenali setiap kelas penyakit. Berdasarkan hasil tersebut, kombinasi EfficientNetB0 dengan *Fine-Tuning* dan *Data Augmentation* dipilih sebagai konfigurasi terbaik untuk dianalisis lebih lanjut pada proses pelatihan dan tahap pengujian *optimizer*.

3.2 Perbandingan *Optimizer* terhadap Performa Model

Setelah diperoleh konfigurasi model terbaik pada tahap sebelumnya, penelitian dilanjutkan dengan menganalisis pengaruh algoritma optimasi terhadap performa klasifikasi penyakit daun pisang. Pengujian dilakukan menggunakan empat *optimizer*, yaitu Adam, AdamW, RMSprop, dan SGD, yang diterapkan pada arsitektur EfficientNetB0 dengan kombinasi *Fine-Tuning* dan *Data Augmentation*. Seluruh *optimizer* menggunakan konfigurasi pelatihan yang sama, meliputi jumlah *epoch*, ukuran citra, *batch size*, serta pembagian dataset yang identik. Dengan demikian, setiap perbedaan performa yang diperoleh mencerminkan pengaruh mekanisme optimasi masing-masing algoritma terhadap proses pembelajaran model.

Optimizer merupakan komponen penting dalam proses pelatihan model *deep learning* karena berperan dalam memperbarui bobot jaringan berdasarkan nilai gradien yang diperoleh selama proses *backpropagation*. Setiap *optimizer* memiliki strategi yang berbeda dalam menentukan arah dan besar pembaruan bobot sehingga dapat menghasilkan kecepatan konvergensi maupun performa klasifikasi yang berbeda. Oleh karena itu, pemilihan *optimizer* yang tepat menjadi salah satu faktor yang dapat memengaruhi kualitas model secara keseluruhan. Hasil pengujian empat *optimizer* disajikan pada Tabel 5.

Tabel 5. Hasil Perbandingan *Optimizer*

<i>Optimizer</i>	<i>Accuracy</i> (%)	<i>Precision</i> (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)
Adam	97,89	98,58	97,89	98,00
RMSprop	96,48	96,48	96,48	96,00
AdamW	95,77	96,45	95,77	96,00
SGD	92,96	94,29	92,96	93,00

Berdasarkan Tabel 5, Adam menghasilkan performa terbaik dibandingkan *optimizer* lainnya dengan nilai *accuracy* sebesar 97,89%, *precision* sebesar 98,58%, *recall* sebesar 97,89%, dan *F1-score* sebesar 98,00%. Hasil tersebut menunjukkan bahwa Adam mampu menghasilkan model dengan tingkat klasifikasi yang lebih akurat sekaligus menjaga keseimbangan antara kemampuan mengenali setiap kelas (*recall*) dan ketepatan prediksi (*precision*). Tingginya nilai *F1-score* juga mengindikasikan bahwa performa model tidak hanya bergantung pada satu metrik evaluasi, tetapi tetap konsisten ketika seluruh metrik dipertimbangkan secara bersamaan.

Optimizer RMSprop menempati urutan kedua dengan nilai *accuracy* sebesar 96,48%. Meskipun performanya cukup baik, nilai evaluasi yang diperoleh masih berada di bawah Adam pada seluruh metrik pengujian. Hal tersebut menunjukkan bahwa RMSprop mampu melakukan pembaruan bobot secara stabil, namun belum dapat menghasilkan parameter model yang seoptimal Adam pada dataset BananaLSD. Perbedaan performa ini diduga disebabkan oleh


mekanisme penyesuaian *learning rate* Adam yang memanfaatkan estimasi momen pertama dan kedua sehingga proses pembelajaran menjadi lebih adaptif.

Pada *optimizer* AdamW, nilai *accuracy* yang diperoleh sebesar 95,77% dengan *F1-score* sebesar 96,00%. Meskipun AdamW dirancang untuk meningkatkan kemampuan generalisasi melalui penerapan *weight decay*, hasil penelitian menunjukkan bahwa pendekatan tersebut belum memberikan peningkatan performa dibandingkan Adam. Penambahan regularisasi yang terlalu kuat dapat menyebabkan proses pembelajaran menjadi lebih konservatif sehingga model tidak sepenuhnya memanfaatkan karakteristik dataset yang tersedia. Akibatnya, performa klasifikasi sedikit menurun dibandingkan *optimizer* Adam.

Berbeda dengan tiga *optimizer* sebelumnya, SGD menghasilkan performa terendah dengan nilai *accuracy* sebesar 92,96% dan *F1-score* sebesar 93,00%. Nilai tersebut menunjukkan bahwa proses konvergensi berlangsung lebih lambat sehingga model belum mencapai kondisi optimum pada jumlah *epoch* yang digunakan. Walaupun SGD dikenal memiliki kemampuan generalisasi yang baik pada beberapa kasus, hasil penelitian ini menunjukkan bahwa *optimizer* tersebut memerlukan proses pelatihan yang lebih panjang atau pengaturan *learning rate* yang lebih spesifik agar mampu menghasilkan performa yang kompetitif.

Secara keseluruhan, hasil pengujian menunjukkan bahwa *optimizer* berbasis *adaptive learning rate* mampu memberikan performa yang lebih baik dibandingkan *optimizer* konvensional pada proses klasifikasi penyakit daun pisang. Dominasi Adam dan RMSprop menunjukkan bahwa kemampuan menyesuaikan *learning rate* secara otomatis membantu model mencapai titik konvergensi yang lebih cepat sekaligus menghasilkan bobot yang lebih optimal. Berdasarkan hasil tersebut, *optimizer* Adam dipilih sebagai konfigurasi terbaik untuk digunakan pada implementasi sistem karena mampu memberikan performa paling tinggi pada seluruh metrik evaluasi.

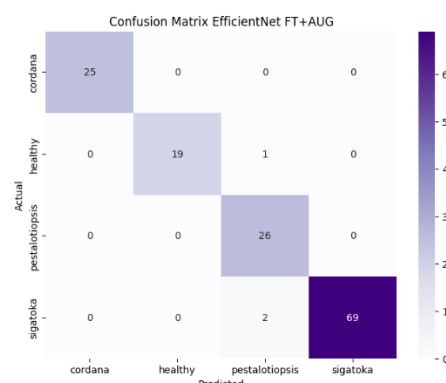
Selanjutnya, proses pembelajaran model menggunakan *optimizer* Adam dianalisis melalui kurva *accuracy-loss* dan *confusion matrix* untuk mengetahui karakteristik pelatihan serta kemampuan model dalam mengklasifikasikan setiap kelas penyakit daun pisang.



Gambar 2. Kurva *Accuracy* dan *Loss* Menggunakan *Optimizer* Adam

Berdasarkan Gambar 2, kurva *training accuracy* mengalami peningkatan secara konsisten hingga mendekati 100%, sedangkan *validation accuracy* tetap stabil pada kisaran 98%. Pola tersebut menunjukkan bahwa *optimizer* Adam mampu mempercepat proses konvergensi tanpa menyebabkan penurunan performa pada data validasi. Di sisi lain, nilai *training loss* dan *validation loss* terus mengalami penurunan hingga akhir proses pelatihan, yang mengindikasikan bahwa model berhasil meminimalkan kesalahan prediksi selama proses pembelajaran.

Stabilitas kurva pelatihan menunjukkan bahwa mekanisme penyesuaian bobot pada Adam mampu menyesuaikan *learning rate* secara adaptif sesuai kondisi gradien pada setiap iterasi. Kemampuan tersebut memungkinkan proses optimasi berlangsung lebih efisien dibandingkan *optimizer* lainnya sehingga model lebih cepat mencapai kondisi konvergen. Selain meningkatkan kecepatan pelatihan, proses pembelajaran yang stabil juga membantu model mempertahankan kemampuan generalisasi terhadap data yang belum pernah digunakan selama proses pelatihan.



Gambar 3. *Confusion Matrix* Menggunakan *Optimizer* Adam

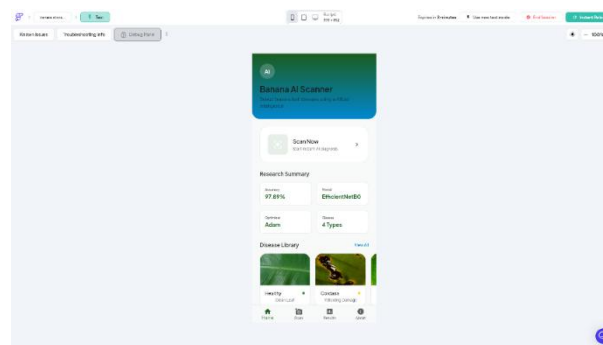
Berdasarkan Gambar 3, hampir seluruh citra berhasil diklasifikasikan sesuai dengan kelas sebenarnya. Kelas *Cordana* menunjukkan hasil klasifikasi sempurna tanpa kesalahan prediksi, sedangkan kelas *Healthy* hanya memiliki satu citra yang diprediksi sebagai *Pestalotiopsis*. Pada kelas *Sigatoka*, sebagian besar citra juga berhasil dikenali dengan benar meskipun memiliki jumlah data paling banyak dalam dataset. Adapun kelas *Pestalotiopsis* masih menjadi kelas yang paling sulit dibedakan karena memiliki karakteristik visual yang cukup mirip dengan beberapa kelas lainnya, namun tingkat kesalahan yang terjadi masih relatif rendah.

Hasil tersebut diperkuat oleh nilai *weighted average F1-score* sebesar 98,00%, yang menunjukkan bahwa model mampu mempertahankan keseimbangan antara *precision* dan *recall* pada seluruh kelas. Dengan demikian, kombinasi EfficientNetB0, *Fine-Tuning*, *Data Augmentation*, dan *optimizer* Adam terbukti mampu menghasilkan model klasifikasi penyakit daun pisang dengan performa yang tinggi, stabil, dan memiliki kemampuan generalisasi yang baik. Kombinasi tersebut selanjutnya digunakan sebagai model akhir pada penelitian ini.

3.3 Implementasi Sistem

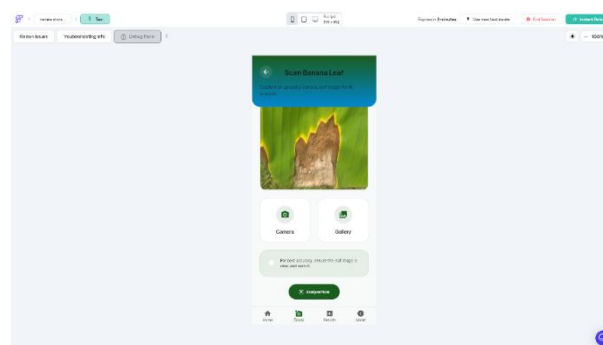
Tahap implementasi dilakukan untuk menerapkan model terbaik hasil penelitian ke dalam sebuah prototipe aplikasi klasifikasi penyakit daun pisang. Model yang dipilih merupakan EfficientNetB0 dengan kombinasi *Fine-Tuning*, *Data Augmentation*, dan *optimizer* Adam, karena menghasilkan performa terbaik pada tahap pengujian dengan nilai *accuracy* sebesar 97,89%. Model tersebut kemudian diintegrasikan ke dalam layanan *Application Programming Interface* (API) menggunakan FastAPI, sehingga proses klasifikasi dapat diakses oleh aplikasi secara real-time.

Antarmuka aplikasi dikembangkan menggunakan FlutterFlow sebagai *platform* pengembangan berbasis *low-code*. Aplikasi dirancang agar pengguna dapat melakukan proses identifikasi penyakit daun pisang melalui perangkat bergerak dengan alur penggunaan yang sederhana. Pengguna dapat memilih citra daun pisang dari galeri maupun mengambil gambar secara langsung menggunakan kamera perangkat, kemudian citra dikirimkan ke layanan API untuk diproses oleh model klasifikasi.



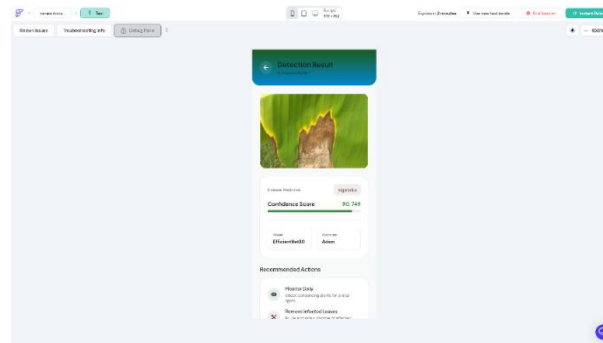
Gambar 4. Halaman Utama Aplikasi

Gambar 4 menampilkan halaman utama aplikasi yang berfungsi sebagai pusat navigasi pengguna. Pada halaman ini ditampilkan informasi singkat mengenai penelitian, model yang digunakan, tingkat akurasi terbaik sebesar 97,89%, serta menu untuk memulai proses klasifikasi penyakit daun pisang. Penyajian informasi tersebut bertujuan memberikan gambaran kepada pengguna mengenai model yang digunakan sebelum melakukan proses deteksi.



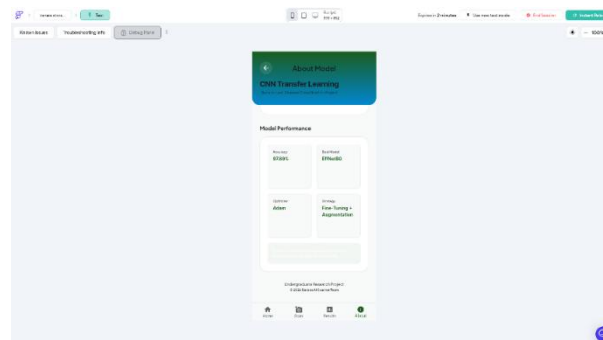
Gambar 5. Halaman *Scan* Daun Pisang

Pada Gambar 5 ditunjukkan halaman pemindaian citra daun pisang. Pengguna dapat memilih gambar melalui galeri maupun mengambil foto secara langsung menggunakan kamera perangkat. Setelah citra dipilih, aplikasi akan mengirimkan gambar ke layanan API untuk diproses menggunakan model EfficientNetB0. Seluruh proses berlangsung secara otomatis sehingga pengguna hanya perlu menekan tombol *Analyze Now* untuk memulai klasifikasi.



Gambar 6. Halaman Hasil Klasifikasi

Gambar 6 memperlihatkan hasil klasifikasi yang diperoleh setelah proses inferensi selesai dilakukan. Halaman ini menampilkan citra yang dianalisis, nama kelas penyakit hasil prediksi, nilai *confidence score*, serta informasi mengenai model dan *optimizer* yang digunakan. Selain itu, aplikasi juga memberikan rekomendasi tindakan sederhana yang dapat dilakukan pengguna sesuai dengan hasil identifikasi penyakit. Penyajian informasi tersebut diharapkan dapat membantu pengguna dalam memahami hasil klasifikasi sekaligus memberikan langkah awal penanganan terhadap penyakit daun pisang yang terdeteksi.



Gambar 7. Halaman Informasi Model

Halaman informasi model ditunjukkan pada Gambar 7. Halaman ini berisi penjelasan mengenai implementasi penelitian, arsitektur model yang digunakan, informasi dataset BananaLSD, jumlah kelas penyakit yang diklasifikasikan, serta konfigurasi model terbaik yang diperoleh selama penelitian. Informasi tersebut disediakan sebagai dokumentasi implementasi sekaligus memberikan transparansi mengenai model yang digunakan dalam proses klasifikasi.

Secara keseluruhan, implementasi sistem menunjukkan bahwa model hasil penelitian berhasil diintegrasikan ke dalam aplikasi berbasis FlutterFlow melalui layanan FastAPI sehingga mampu melakukan proses klasifikasi penyakit daun pisang secara *real-time*. Hasil implementasi ini membuktikan bahwa model yang dikembangkan tidak hanya memiliki performa yang baik pada tahap pengujian, tetapi juga dapat diterapkan sebagai prototipe aplikasi yang mendukung proses identifikasi penyakit daun pisang secara lebih praktis dan mudah digunakan oleh pengguna.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi penyakit daun pisang menggunakan *pendekatan transfer learning* dengan membandingkan dua arsitektur *Convolutional Neural Network* (CNN), yaitu MobileNetV2 dan EfficientNetB0. Pengujian dilakukan melalui delapan skenario eksperimen yang mengombinasikan penerapan *fine-tuning* dan *data augmentation* untuk mengetahui konfigurasi model yang memberikan performa terbaik. Hasil penelitian menunjukkan bahwa setiap skenario menghasilkan tingkat akurasi yang tinggi, namun kombinasi EfficientNetB0 dengan *Fine-Tuning* dan *Data Augmentation* memberikan performa terbaik dengan nilai *accuracy* sebesar 97,89%, *precision* 98,58%, *recall* 97,89%, dan *F1-score* 98,00%. Hasil tersebut menunjukkan bahwa penerapan *fine-tuning* dan *data augmentation* mampu meningkatkan kemampuan model dalam mengklasifikasikan penyakit daun pisang pada dataset BananaLSD. Penelitian ini juga membandingkan beberapa algoritma optimasi, yaitu Adam, AdamW, RMSprop, dan SGD, menggunakan model terbaik yang diperoleh pada tahap sebelumnya. Berdasarkan hasil evaluasi, *optimizer* Adam menghasilkan performa terbaik dibandingkan *optimizer* lainnya sehingga dipilih sebagai konfigurasi akhir model. Model terbaik tersebut kemudian berhasil diimplementasikan ke dalam prototipe aplikasi berbasis FlutterFlow yang terintegrasi dengan layanan FastAPI, sehingga proses klasifikasi penyakit daun pisang dapat dilakukan secara *real-time* melalui perangkat bergerak. Implementasi ini menunjukkan bahwa model yang dikembangkan tidak hanya memberikan performa

klasifikasi yang tinggi pada tahap pengujian, tetapi juga dapat diterapkan sebagai prototipe sistem yang berpotensi membantu proses identifikasi awal penyakit daun pisang secara lebih cepat, praktis, dan mudah digunakan. Penelitian selanjutnya dapat mengembangkan sistem dengan memanfaatkan dataset yang lebih beragam, menambahkan visualisasi *Explainable Artificial Intelligence* (XAI) seperti *Grad-CAM*, serta melakukan pengujian pada kondisi lapangan yang lebih bervariasi untuk meningkatkan interpretabilitas dan kemampuan generalisasi model.

REFERENCES

- [1] Badan Pusat Statistik, “Statistik Hortikultura 2025,” Jakarta, Jun. 2026. Accessed: Jun. 29, 2026. [Online]. Available: <https://www.bps.go.id/id/publication/2026/06/12/43da5ec30fc7d87985e108a5/statistik-hortikultura-2025.html>
- [2] N. Jiménez, S. Orellana, B. Mazon-Olivo, W. Rivas-Asanza, and I. Ramírez-Morales, “Detection of Leaf Diseases in Banana Crops Using Deep Learning Techniques,” *AI (Switzerland)*, vol. 6, no. 3, Mar. 2025, doi: 10.3390/ai6030061.
- [3] S. E. Arman, Md. Abdullahil Baki Bhuiyan, H. Muhammad Abdullah, S. Islam, T. Tanha Chowdhury, and Md. Arban Hossain, “Banana Leaf Images Dataset for Classification of Banana Leaf Diseases Using Machine Learning,” *Data Brief*, vol. 50, p. 109608, Sep. 2023, doi: 10.1016/j.dib.2023.109608.
- [4] M. Shoaib *et al.*, “An advanced deep learning models-based plant disease detection: A review of recent research,” 2023, *Frontiers Media SA*. doi: 10.3389/fpls.2023.1158933.
- [5] J. Zhao *et al.*, “A review of plant leaf disease identification by deep learning algorithms,” 2025, *Frontiers Media SA*. doi: 10.3389/fpls.2025.1637241.
- [6] M. Shoaib, A. Sadeghi-Niaraki, F. Ali, I. Hussain, and S. Khalid, “Leveraging deep learning for plant disease and pest detection: a comprehensive review and future directions,” 2025, *Frontiers Media SA*. doi: 10.3389/fpls.2025.1538163.
- [7] M. D. Pratama, R. Gustriansyah, and E. Purnamasari, “Klasifikasi Penyakit Daun Pisang menggunakan Convolutional Neural Network (CNN),” *Jurnal Teknologi Terpadu*, vol. 10, no. 1, Jul. 2024, doi: 10.54914/jtt.v10i1.1167.
- [8] Ni. Helmawati and E. Utami, “Analysis for Detecting Banana Leaf Disease Using the CNN Method,” *JUITA: Jurnal Informatika*, vol. 13, no. 1, pp. 29–36, Mar. 2025, doi: 10.30595/juita.v13i1.24514.
- [9] N. Helmawati and E. Utami, “Utilization of the Convolutional Neural Network Method for Detecting Banana Leaf Disease,” *Jurnal RESTI*, vol. 8, no. 6, pp. 799–805, Dec. 2024, doi: 10.29207/resti.v8i6.6140.
- [10] C. Nastitie, I. Handayani, and U. T. Yogyakarta, “PERBANDINGAN METODE MOBILENETV2 DAN EFFICIENTNETB0 UNTUK KLASIFIKASI JENIS PISANG COMPARISON OF MOBILENETV2 AND EFFICIENTNETB0 METHODS FOR BANANA TYPE CLASSIFICATION,” *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 8, no. 6, pp. 1990–1999, Nov. 2025, doi: 10.31539/0240cx09.
- [11] M. Syifa Aryanta, C. A. Sari, and H. Rachmawanto, “A Banana Disease Detection Using MobileNetV2 Model Based on Adam Optimizer,” *Journal of Applied Informatics and Computing (JAIC)*, vol. 9, no. 4, pp. 1207–1218, Aug. 2025, doi: 10.30871/jaic.v9i4.9870.
- [12] H. Ali, N. Shifa, R. Benlamri, A. A. Farooque, and R. Yaqub, “A fine tuned EfficientNet-B0 convolutional neural network for accurate and efficient classification of apple leaf diseases,” *Sci. Rep.*, vol. 15, no. 1, p. 25732, 2025, doi: 10.1038/s41598-025-04479-2.
- [13] Y. Ferdi, “Data Augmentation through Background Removal for Apple Leaf Disease Classification Using the MobileNetV2 Model,” *ArXiv*, Jun. 2024, doi: 10.48550/arXiv.2412.01854.
- [14] M. F. Aulia, M. K. Gibran, N. S. A. Sitorus, A. Nugroho, N. Faiza, and H. A. R. Siregar, “Transfer Learning Implementation with MobileNetV2 for Cassava Leaf Disease Detection,” *JURNAL TEKNOLOGI DAN OPEN SOURCE*, vol. 8, no. 1, pp. 352–361, Jun. 2025, doi: 10.36378/jtos.v8i1.4442.

- [15] S. E. Thio and J. Susilo, "Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0," *bit-Tech*, vol. 8, no. 1, pp. 25–32, Aug. 2025, doi: 10.32877/bt.v8i1.1900.
- [16] B. Fadhil Mohammad and A. Dijah Rahajoe, "Optimizing CNN-Based Transfer Learning through Fine-Tuning and Adaptive Augmentation for Chili Plant Disease Detection," *SISFO Jurnal Ilmiah*, vol. 10, no. 1, pp. 306–315, 2026, doi: 10.29103/sisfo.
- [17] Z. R. Mair, R. Heriansyah, and L. O. H. S. Sagala, "Performance Comparison of Adam and SGD Optimizers in Transfer Learning Based CNN for Banana Leaf Disease Classification," *Jurnal Sains, Nalar, dan Aplikasi Teknologi Informasi*, vol. 5, no. 1, pp. 8–15, Jan. 2026, doi: 10.20885/snati.v5.i1.43901.
- [18] N. Uly, H. Hendry, and A. Iriani, "CNN-RNN Hybrid Model for Diagnosis of COVID-19 on X-Ray Imagery," *Digital Zone: Jurnal Teknologi Informasi dan Komunikasi*, vol. 14, no. 1, pp. 57–67, May 2023, doi: 10.31849/digitalzone.v14i1.13668.
- [19] A. I. R. H. Barat, W. S. Astuti, D. Hartama, A. P. Windarto, and A. Wanto, "ENHANCED FLOWER IMAGE CLASSIFICATION USING MOBILENETV2 WITH OPTIMIZED PERFORMANCE," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 11, no. 1, pp. 180–191, Aug. 2025, doi: 10.33480/jitk.v11i1.6497.