



Implementasi *Deep Learning* Untuk Klasifikasi Penyakit Pada Daun Kelapa Sawit Menggunakan Arsitektur MobileNetV2

Habil Putra Arianda^{*1}, T. Yudi Hadiwandra²

Email: ¹habil.putra2363@student.unri.ac.id, ²tyudihw@lecturer.unri.ac.id

¹Program Studi Teknik Informatika, Fakultas Teknik, Universitas Riau

²Program Studi Teknik Informatika, Fakultas Teknik, Universitas Riau

Diterima: 30 September 2025 | Direvisi: - | Disetujui: 14 Desember 2025

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Identifikasi penyakit pada daun kelapa sawit secara akurat dan efisien merupakan tantangan krusial dalam upaya mempertahankan produktivitas perkebunan, guna mencegah kerugian hasil panen yang signifikan. Keterbatasan akses terhadap pakar dan kecepatan deteksi di lapangan seringkali menjadi kendala. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun kelapa sawit menggunakan pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2. Model ini memanfaatkan strategi *transfer learning* dari bobot *pre-trained* ImageNet dan dioptimalkan melalui strategi pelatihan dua fase pada dataset yang terdiri dari 1200 gambar daun kelapa sawit yang telah diaugmentasi, mencakup empat kelas yaitu, *Healthy Sample*, *Fusarium Wilt*, *Parlatoria Blanchardi*, dan *Rachis Blight*. Hasil pengujian model menunjukkan akurasi sebesar 85% pada data uji terpisah. Arsitektur MobileNetV2 dipilih karena karakteristiknya yang ringan, sehingga model ini efisien dan berpotensi tinggi untuk diimplementasikan pada perangkat *mobile* untuk membantu identifikasi penyakit secara cepat di lapangan dan mendukung pengambilan keputusan oleh petani.

Kata kunci: *Deep Learning, Klasifikasi Gambar, MobileNetV2, Penyakit Daun Kelapa Sawit, Aplikasi Mobile.*

Implementation of Deep Learning for Disease Classification in Oil Palm Leaves Using the MobileNetV2 Architecture

Abstract

Accurate and efficient identification of diseases in oil palm leaves is a crucial challenge in maintaining plantation productivity and preventing significant crop losses. Limited access to experts and slow detection in the field are often obstacles. This study aims to develop a palm oil leaf disease classification model using a deep learning approach based on Convolutional Neural Network (CNN) with MobileNetV2 architecture. This model utilizes a transfer learning strategy from pre-trained ImageNet weights and is optimized through a two-phase training strategy on a dataset consisting of 1200 augmented oil palm leaf images, covering four classes, namely Healthy Sample, Fusarium Wilt, Parlatoria Blanchardi, and Rachis Blight. Model testing results show an accuracy of 85% on separate test data. The MobileNetV2 architecture was chosen for its lightweight characteristics, making this model efficient and highly suitable for implementation on mobile devices to assist in rapid disease identification in the field and support decision-making by farmers.

Keywords: *Deep Learning, Image Classification, MobileNetV2, Oil Palm Leaf Disease, Mobile Application*

1. PENDAHULUAN

Kelapa sawit (*Elaeis Guineensis*) merupakan komoditas strategis bagi perekonomian Indonesia, namun produktivitasnya seringkali terancam oleh serangan penyakit pada daun [1]. Kerusakan daun secara signifikan menurunkan efisiensi fotosintesis dan hasil panen, bahkan dapat menyebar luas jika tidak segera diidentifikasi dan ditangani [2]. Proses identifikasi penyakit secara manual oleh tenaga ahli di lapangan memiliki keterbatasan dalam hal waktu, akurasi, dan skala, terutama untuk perkebunan luas [3]. Oleh karena itu, diperlukan pendekatan yang lebih cepat, efisien, dan akurat.

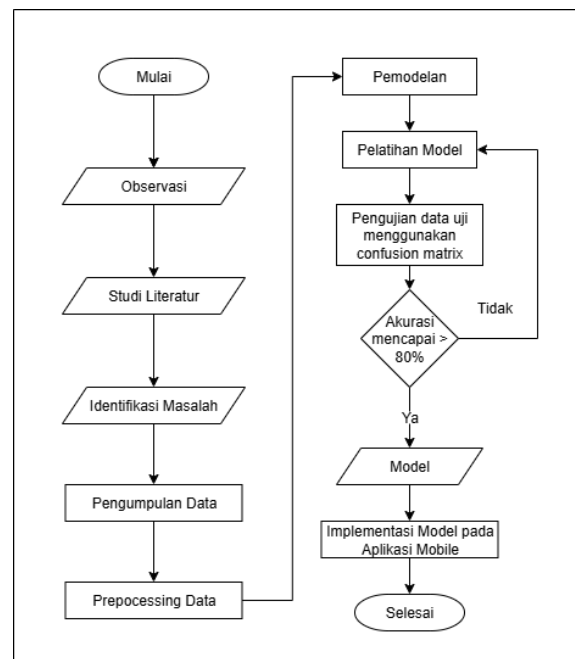
Pemanfaatan *deep learning* dengan *Convolutional Neural Network* (CNN) telah terbukti sangat efektif dalam pengolahan dan klasifikasi citra, termasuk dalam diagnosis penyakit tanaman [4]. Berbagai penelitian telah berhasil menerapkan CNN untuk deteksi penyakit maupun identifikasi varietas tanaman. Sebagai contoh, penelitian oleh Pratama et al. [5] berhasil mengklasifikasikan varietas alpukat berdasarkan citra daun menggunakan model *pre-trained* SSDMobileNetV2 FPN-Lite dengan akurasi mencapai 99%. Studi lain oleh Raynold dan Muhammad [6] menggunakan arsitektur ResNet-50 untuk mendeteksi 10 kelas penyakit pada daun tomat dan memperoleh akurasi sebesar 93%. Penelitian oleh Surya dan Gautama [7] menggunakan arsitektur MobileNetV2 untuk klasifikasi penyakit pada daun singkong dan mencapai akurasi 74,96%. Sementara itu, pada konteks yang lebih spesifik, penelitian oleh Satia et al. [3] mengembangkan sistem deteksi penyakit pada daun kelapa sawit dengan CNN yang mencapai akurasi 85,5% dan mengimplementasikannya dalam aplikasi android untuk membantu petani melakukan deteksi secara *real-time*.

Meskipun CNN efektif, penerapannya masih menghadapi tantangan seperti kualitas gambar tidak seragam, data tidak seimbang, dan kemiripan gejala penyakit yang dapat menurunkan generalisasi model. Mengidentifikasi celah ini, penelitian ini menggunakan pendekatan *transfer learning* dengan arsitektur MobileNetV2, yang dikenal ringan secara komputasi namun akurat. Dataset diambil dari kaggle untuk konsistensi kualitas, dan augmentasi data dilakukan untuk mengatasi ketidakseimbangan kelas.

Penelitian ini difokuskan pada klasifikasi tiga jenis penyakit daun kelapa sawit (*Rachis Blight*, *Parlatoria Blanchardi*, *Fusarium Wilt*) serta daun sehat. Model akan dilatih, divalidasi, dan dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*. Selanjutnya, model akan diimplementasikan ke dalam aplikasi *mobile* berbasis android untuk diagnosis cepat dan praktis di lapangan, diharapkan dapat meningkatkan akurasi dan efisiensi diagnosis penyakit, mengurangi ketergantungan pada ahli, serta mendukung keberlanjutan perkebunan.

2. METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen, yang berfokus pada pemberian perlakuan terhadap suatu variabel untuk melihat pengaruhnya terhadap hasil tertentu [8]. Alur sistematis yang dilakukan dalam penelitian ini diilustrasikan secara rinci pada gambar 1.



Gambar 1. Alur Penelitian

2.1. Observasi

Pada tahap observasi, dilakukan pengamatan langsung di perkebunan kelapa sawit yang dikelola oleh masyarakat. Proses ini berfokus pada identifikasi gejala visual penyakit yang umum ditemukan pada daun, seperti bercak, perubahan warna, dan kerusakan fisik lainnya. Selain pengamatan visual, dilakukan interaksi dengan para petani untuk memahami kesulitan yang mereka hadapi dalam membedakan berbagai jenis penyakit. Hasil observasi menunjukkan adanya tantangan signifikan bagi petani dalam mengidentifikasi penyakit secara akurat hanya berdasarkan gejala visual, terutama karena beberapa penyakit memiliki kemiripan. Kesulitan ini menjadi dasar utama penelitian untuk mengembangkan sistem yang dapat membantu diagnosis penyakit secara lebih cepat dan tepat.

2.2. Studi Literatur


Studi literatur dalam penelitian ini bertujuan untuk membentuk landasan teori dan pemahaman mendalam mengenai topik penelitian. Sumber literatur yang dikaji meliputi jurnal ilmiah, buku referensi, dan penelitian terdahulu yang relevan. Kajian ini berfokus pada topik deteksi penyakit tanaman pada kelapa sawit, serta penerapan teknologi *deep learning*, arsitektur CNN, metode *transfer learning*, dan implementasi MobileNetV2 untuk klasifikasi citra.

2.3. Identifikasi Masalah

Proses identifikasi masalah dilakukan berdasarkan hasil dari tahap observasi dan studi literatur, dengan tujuan untuk merumuskan permasalahan utama yang akan diselesaikan dalam penelitian. Ditemukan bahwa metode konvensional untuk mendeteksi penyakit daun kelapa sawit secara visual tidak efisien dan rentan terhadap kesalahan. Selain itu, penerapan arsitektur *deep learning* yang ringan dan efisien untuk solusi berbasis *mobile* pada kasus ini masih terbatas, sehingga menjadi celah yang akan dijawab dalam penelitian ini.

2.4. Pengumpulan Data

Pada penelitian ini, dataset yang digunakan bersifat publik dan bersumber dari platform kaggle. Dataset ini terdiri dari total 1.200 gambar berkualitas tinggi dengan format png, yang dikelompokkan ke dalam empat kelas, yaitu *Rachis Blight* (busuk tulang daun), *Parlatoria Blanchardi* (serangan kutu sisik), *Fusarium Wilt* (layu fusarium), dan *Healthy Sample* (daun sehat). Untuk kebutuhan pelatihan dan evaluasi model, keseluruhan data dibagi menjadi tiga bagian: 80% data latih (960 gambar), 10% data validasi (120 gambar), dan 10% data uji (120 gambar). Contoh visualisasi untuk setiap kelas dari dataset yang digunakan dapat dilihat pada gambar 2.



Gambar 2. Citra Daun Kelapa Sawit

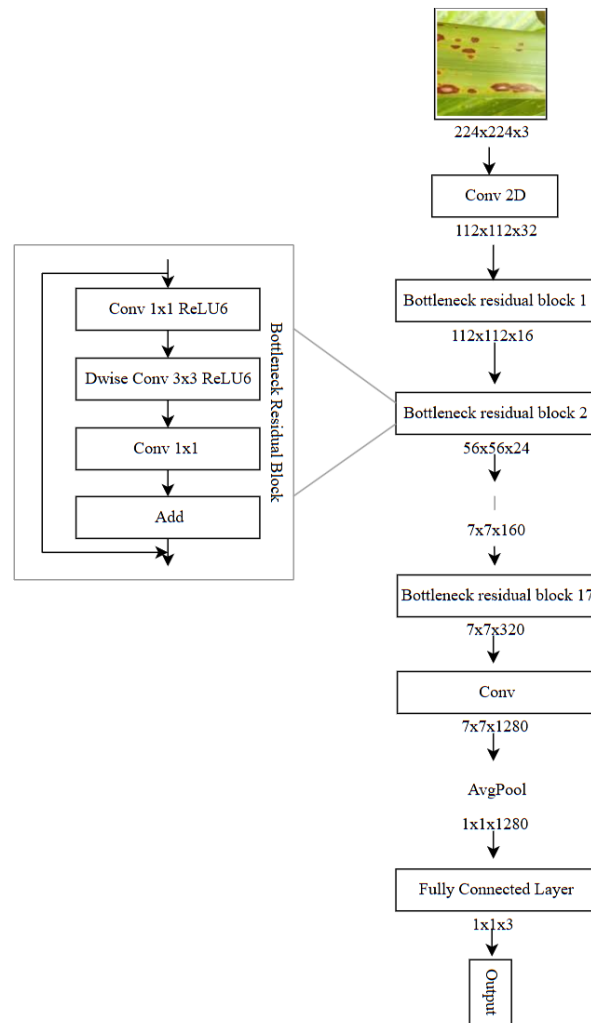
2.5. Preprocessing Data

Preprocessing data adalah proses mengolah data mentah menjadi format yang lebih terstruktur dan siap untuk analisis lebih lanjut. Tujuan utamanya adalah meningkatkan kualitas data agar model yang dibangun menjadi lebih akurat [9]. Tahap pertama dalam proses ini adalah *resizing*, di mana seluruh citra diubah ukurannya menjadi 224x224 piksel untuk memenuhi standar *input* yang dibutuhkan oleh arsitektur MobileNetV2. Selanjutnya, dilakukan augmentasi data untuk memperbanyak jumlah dan variasi data latih secara signifikan. Berbagai teknik augmentasi diterapkan, antara lain *rotation*, *zooming*, dan *flipping*, untuk membantu model agar lebih tangguh dan mampu mengenali pola penyakit dalam berbagai kondisi.

2.6. Pemodelan

Pada tahap ini, model klasifikasi dirancang menggunakan arsitektur MobileNetV2 dengan pendekatan *transfer learning*. Model dasar ini dimuat dengan bobot pra-trlatih dari *dataset* ImageNet dan tanpa lapisan klasifikasi teratas (*include_top=False*). Seluruh lapisan pada model dasar awalnya dibekukan (*frozen*). Di atasnya, ditambahkan kepala klasifikasi kustom yang terdiri

dari lapisan *GlobalAveragePooling2D*, lapisan *Dropout* dengan *rate* 0.5, dan lapisan *Dense* dengan 4 *neuron* serta aktivasi *softmax* sebagai *output*. Arsitektur ini diilustrasikan pada Gambar 3.



Gambar 3. Arsitektur Model

2.7. Pelatihan Model

Proses pelatihan model dilakukan dalam dua fase menggunakan *optimizer* Adam dan fungsi *loss* categorical crossentropy. Fase pertama (*Feature Extraction*), seluruh lapisan model dasar dibekukan dan hanya kepala klasifikasi yang dilatih selama 15 *epoch* dengan *learning rate* 0.01. Fase kedua (*Fine-Tuning*), lapisan-lapisan atas dari model dasar (mulai dari lapisan ke-100) diaktifkan kembali (*unfrozen*) dan dilatih dengan *learning rate* yang sangat rendah, yaitu 1e-5, hingga maksimal 50 *epoch*. Proses *fine-tuning* ini dikontrol oleh *callbacks* *EarlyStopping* (*patience*=10) untuk mencegah *overfitting* dan *ReduceLROnPlateau* (*patience*=3) untuk menyesuaikan *learning rate* secara dinamis.

2.8. Pengujian Model

Tahap pengujian bertujuan untuk mengevaluasi performa akhir model pada data yang belum pernah dilihat sebelumnya. Proses ini menggunakan data uji sebanyak 120 gambar (10% dari total dataset), yang terdiri dari 30 gambar untuk masing-masing dari empat kelas. Model MobileNetV2 yang telah dilatih digunakan untuk memprediksi kelas dari setiap gambar uji, dan hasilnya dibandingkan dengan label sebenarnya menggunakan *confusion matrix*. Performa model dianalisis menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*. Model dianggap berhasil dan layak untuk implementasi *mobile* jika mencapai standar akurasi di atas 80%.

3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari eksperimen yang telah dilakukan sesuai dengan metode penelitian yang diuraikan pada bab sebelumnya.

3.1. Hasil Pelatihan Model

Pada tahap ini, dilakukan proses pelatihan dan optimasi *hyperparameter* untuk menemukan konfigurasi model terbaik. Sembilan percobaan dilakukan menggunakan pendekatan *grid search* dengan variasi *learning rate* (0.01, 0.001, 0.0001) dan *batch size* (16, 32, 64). Untuk semua percobaan, *optimizer* yang digunakan adalah Adam, yang dikenal memiliki konvergensi yang efisien untuk berbagai kasus *deep learning* [10]. Mekanisme *EarlyStopping* diterapkan untuk menghentikan pelatihan saat performa validasi tidak lagi meningkat, guna mencegah *overfitting* dan efisiensi waktu. Hasil ringkas dari kesembilan percobaan tersebut disajikan pada Tabel 1.

Tabel 1. Hasil Pelatihan Model

Percobaan	Learning Rate	Batch Size	Accuracy		Selisih Akurasi	Loss	
			Train	Valid		Train	Valid
1	0.01	16	0.7234	0.8417	0.1183	2.3710	1.3119
2	0.01	32	0.8106	0.8917	0.0811	0.8572	0.7054
3	0.01	64	0.8201	0.8917	0.0716	0.5691	0.5266
4	0.001	16	0.7853	0.8917	0.1064	0.6057	0.3967
5	0.001	32	0.8257	0.8667	0.0410	0.5118	0.3946
6	0.001	64	0.8743	0.8583	-0.0160	0.3319	0.4000
7	0.0001	16	0.9895	0.8833	-0.1062	0.0305	0.2885
8	0.0001	32	0.9743	0.8000	-0.1743	0.1184	0.5183
9	0.0001	64	0.9920	0.8083	-0.1837	0.0498	0.5590

Berdasarkan Tabel 1, konfigurasi pada percobaan 2 dengan *learning rate* 0.01 dan *batch size* 32 dipilih sebagai model final, karena berhasil mencapai akurasi tertinggi pada data uji yaitu 85.00%. Meskipun beberapa percobaan lain menunjukkan akurasi validasi yang tinggi, model ini memberikan kemampuan generalisasi terbaik pada data yang belum pernah dilihat sebelumnya. *Learning curve* untuk model terbaik disajikan pada Gambar 4.




Gambar 4. Grafik Pelatihan Model Terbaik

Seperti yang terlihat pada Gambar 4, model mencapai performa puncaknya pada *epoch* ke-16, dengan akurasi validasi sebesar 89.17%, lebih tinggi dari akurasi pelatihannya yaitu 81.06%. Selisih positif ini menunjukkan kemampuan generalisasi yang baik pada titik optimalnya. Meskipun kurva menunjukkan fluktuasi, *EarlyStopping* berhasil mengamankan model pada kondisi terbaiknya sebelum terjadi *overfitting*.

3.2. Hasil Pengujian Model

Setelah model terbaik dipilih, dilakukan pengujian akhir untuk mengukur performa secara objektif pada 120 gambar data uji yang belum pernah dilihat oleh model. Evaluasi performa dilakukan menggunakan *confusion matrix* untuk menyajikan rincian prediksi dan menghitung metrik *Precision*, *Recall*, dan *F1-Score*. Hasil pengujian menunjukkan model berhasil memprediksi

102 dari 120 gambar dengan benar, sehingga mencapai akurasi keseluruhan sebesar 85.00%. *Confusion matrix* dari hasil pengujian disajikan pada Gambar 5.



Gambar 5. Confusion Matrix Hasil Pengujian

Kinerja model dievaluasi menggunakan beberapa metrik standar yang dihitung dari *confusion matrix* [11].

$$Accuracy = \frac{Jumlah\ Prediksi\ Benar}{Jumlah\ Keseluruhan\ Data\ Uji} \dots\dots\dots(1)$$

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

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

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

Dengan keterangan, TP (*True Positive*) adalah data positif yang diprediksi benar, TN (*True Negative*) adalah data negatif yang diprediksi benar, FP (*False Positive*) adalah data negatif yang salah diprediksi sebagai positif, dan FN (*False Negative*) adalah data positif yang salah diprediksi sebagai negatif.

1. Akurasi Keseluruhan

$$Accuracy = \frac{Jumlah\ Prediksi\ Benar}{Jumlah\ Keseluruhan\ Data\ Uji} = \frac{102}{120} = 0.85$$

Akurasi keseluruhan model adalah 0.85 atau 85.00%. Angka ini menunjukkan bahwa model mampu mengklasifikasikan 85% dari seluruh data uji dengan tepat.

2. Kelas *Fusarium Wilt*

Diketahui, *True Positives* (TP) adalah 22, *False Positives* (FP) adalah 2, dan *False Negatives* (FN) adalah 8.

$$Precision = \frac{TP}{TP + FP} = \frac{22}{22 + 2} = \frac{22}{24} = 0.916 \approx 0.92$$

Nilai *precision* 0.92 berarti dari semua gambar yang diprediksi oleh model sebagai *Fusarium Wilt*, 92% di antaranya memang benar *Fusarium Wilt*.

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{22}{22 + 8} = \frac{22}{30} = 0.733 \approx 0.73$$

Nilai *recall* 0.73 berarti dari semua gambar *Fusarium Wilt* yang asli di data uji, model berhasil mendeteksi dan mengenali 73% di antaranya.

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \times \frac{0.92 \times 0.73}{0.92 + 0.73} = 0.814 \approx 0.81$$

Nilai *F1 Score* 0.81 menunjukkan keseimbangan yang baik antara *precision* dan *recall* untuk kelas *Fusarium Wilt*.

3. Kelas *Healthy Sample*

Diketahui, *True Positives* (TP) adalah 24, *False Positives* (FP) adalah 6, dan *False Negatives* (FN) adalah 6.

$$\text{Precision} = \frac{TP}{TP + FP} = \frac{24}{24 + 6} = \frac{24}{30} = 0.80$$

Nilai *precision* 0.80 menunjukkan bahwa 80% dari gambar yang diprediksi sebagai sampel sehat memang benar-benar sehat.

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{24}{24 + 6} = \frac{24}{30} = 0.80$$

Nilai *recall* 0.80 menunjukkan bahwa model berhasil mengenali 80% dari seluruh sampel sehat yang ada.

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \times \frac{0.80 \times 0.80}{0.80 + 0.80} = 0.80$$

Dengan *precision* dan *recall* yang seimbang, nilai *F1 Score* 0.80 menunjukkan performa yang konsisten untuk kelas ini.

4. Kelas *Parlatoria Blanchardi*

Diketahui, *True Positives* (TP) adalah 28, *False Positives* (FP) adalah 3, dan *False Negatives* (FN) adalah 2.

$$\text{Precision} = \frac{TP}{TP + FP} = \frac{28}{28 + 3} = \frac{28}{31} = 0.903 \approx 0.90$$

Nilai *precision* 0.90 menandakan tingkat keakuratan yang tinggi saat model menebak sebuah gambar sebagai *Parlatoria Blanchardi*.

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{28}{28 + 2} = \frac{28}{30} = 0.933 \approx 0.93$$

Nilai *recall* 0.93 sangat tinggi, artinya model sangat efektif dalam menemukan hampir semua kasus *Parlatoria Blanchardi*.

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \times \frac{0.90 \times 0.93}{0.90 + 0.93} = 0.914 \approx 0.92$$

Nilai *F1 Score* 0.92 merupakan yang tertinggi, menunjukkan kelas ini adalah kelas yang paling baik dikenali oleh model.

5. Kelas *Rachis Blight*

Diketahui, *True Positives* (TP) adalah 28, *False Positives* (FP) adalah 7, dan *False Negatives* (FN) adalah 2.

$$Precision = \frac{TP}{TP + FP} = \frac{28}{28 + 7} = \frac{28}{35} = 0.80$$

Nilai *precision* 0.80 berarti ketika model memprediksi *Rachis Blight*, 80% tebakannya benar.

$$Recall = \frac{TP}{TP + FN} = \frac{28}{28 + 2} = \frac{28}{30} = 0.933 \approx 0.93$$

Seperti *Parlatoria Blanchardi*, nilai *recall* 0.93 yang tinggi menunjukkan model sangat andal dalam mendeteksi penyakit *Rachis Blight*.

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{0.80 \times 0.93}{0.80 + 0.93} = 0.860 \approx 0.86$$

Nilai *F1-Score* 0.86 menunjukkan performa yang sangat baik secara keseluruhan untuk kelas *Rachis Blight*.

3.3. Perbandingan dengan Penelitian Terdahulu

Untuk mengevaluasi kinerja model, performa model dibandingkan dengan penelitian terdahulu yang relevan. Perbandingan ini disajikan pada Tabel 2, dengan fokus pada arsitektur model yang digunakan dan akurasi yang dicapai.

Tabel 2. Perbandingan Kinerja Model

Penulis	Objek Penelitian	Arsitektur Model	Akurasi
Surya dan Gautama [7]	Daun Singkong	MobileNetV2	74.96%
Satia et al. [3]	Daun Kelapa Sawit	CNN (Umum)	85.05%
Pratama et al. [5]	Daun Alpukat	SSDMobileNetV2	99.00%
Penelitian Ini	Daun Kelapa Sawit	MobileNetV2	85.00%

Berdasarkan perbandingan pada Tabel 2, model MobileNetV2 dalam penelitian ini menunjukkan kinerja yang sangat kompetitif dengan akurasi 85.00%. Hasil ini secara signifikan lebih unggul dibandingkan penelitian oleh Surya dan Gautama [7] yang menggunakan arsitektur MobileNetV2 pada kasus daun singkong dengan akurasi 74.96%, menunjukkan efektivitas model pada dataset kelapa sawit. Ketika dibandingkan dengan Satia et al. [3] yang meneliti objek yang sama, akurasi yang dicapai hampir sebanding yaitu 85.5%. Namun, penelitian ini memberikan keunggulan dengan mengimplementasikan pada perangkat *mobile*. Sementara itu, meskipun Pratama et al. [5] mencapai akurasi 99% pada daun alpukat, penelitian tersebut berfokus pada klasifikasi varietas yang memiliki ciri visual berbeda, sedangkan penelitian ini berhasil mengatasi tantangan klasifikasi gejala penyakit yang seringkali memiliki kemiripan.

3.4. Implementasi Model Pada Aplikasi Mobile

Sebagai tahap akhir, model MobileNetV2 yang telah dilatih diimplementasikan ke dalam sebuah aplikasi *mobile* berbasis android untuk memvalidasi fungsionalitasnya dalam skenario penggunaan praktis. Aplikasi ini mengintegrasikan model dalam format TensorFlow Lite (.tflite), yang memungkinkan seluruh proses inferensi dijalankan secara langsung pada perangkat (*on-device*) tanpa memerlukan koneksi internet.

Alur kerja aplikasi, seperti yang ditunjukkan pada Gambar 6, memungkinkan pengguna mengunggah citra daun dari galeri, yang kemudian dianalisis oleh model untuk menampilkan hasil klasifikasi. Hasil tersebut disajikan secara langsung kepada pengguna berupa nama penyakit yang terdeteksi beserta skor prediksinya. Implementasi ini berfungsi sebagai *proof-of-concept* bahwa model yang dikembangkan dapat menjadi alat bantu diagnosis penyakit yang cepat dan efisien di lapangan.



Gambar 6. Alur Kerja Aplikasi

4. KESIMPULAN

Penelitian ini menunjukkan bahwa arsitektur MobileNetV2 efektif untuk mengklasifikasikan empat kondisi daun kelapa sawit (*Healthy Sample*, *Fusarium Wilt*, *Parlatoria Blanchardi*, dan *Rachis Blight*). Model terbaik, yang diperoleh melalui optimasi *hyperparameter* dengan *learning rate* 0.01 dan *batch size* 32, berhasil mencapai akurasi sebesar 85.00% pada data uji. Kinerja yang stabil selama pelatihan, dengan akurasi validasi mencapai 89.17%, membuktikan kemampuan generalisasi model yang baik tanpa mengalami *overfitting* yang signifikan. Selain akurasi yang solid, arsitektur MobileNetV2 menawarkan keseimbangan antara performa dan efisiensi komputasi, menjadikannya solusi yang layak untuk diimplementasikan pada aplikasi *mobile* sebagai alat bantu diagnosis di lapangan.

DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, "Produksi Tanaman Perkebunan (Ribuan Ton), 2023," Badan Pusat Statistik.
- [2] C. Adhityansyah, J. Eliel, T. Tampubolon, F. Natalis Eduk, and M. Razik, "Literature Review: Klasifikasi Penyakit Daun Tanaman Kelapa Sawit Menggunakan Convolutional Neural Network," *OKTAL : Jurnal Ilmu Komputer dan Science*, vol. 3, no. 10, 2024, [Online]. Available: <https://journal.mediapublikasi.id/index.php/oktal>
- [3] G. A. W. Satia, E. Firmansyah, and A. Umami, "Perancangan sistem identifikasi penyakit pada daun kelapa sawit (*Elaeis guineensis* Jacq.) dengan algoritma deep learning convolutional neural networks," *Jurnal Ilmiah Pertanian*, vol. 19, no. 1, pp. 1–10, Mar. 2022, doi: 10.31849/jip.v19i1.9556.
- [4] Q. A'yuni and B. Hendrik, "Literature Review: Analisis Komparatif Algoritma CNN, KNN, dan SVM untuk Klasifikasi Penyakit Kelapa Sawit," *Journal of Education Research*, vol. 5, no. 4, 2024.
- [5] A. Pratama, T. Sugiharto, and P. Novantara, "Klasifikasi Jenis Tanaman Alpukat Berdasarkan Bentuk Daun Menggunakan Algoritma CNN," *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 2, pp. 120–128, 2025, doi: 10.37859/coscitech.v6i2.9474.
- [6] R. Raynold and Alva Hendi Muhammad, "Deep Learning Deteksi Dan Klasifikasi Penyakit Daun Tomat Menggunakan ResNet-50," *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 1, pp. 9–20, Apr. 2025, doi: 10.37859/coscitech.v6i1.8501.
- [7] R. Surya and E. Gautama, "Cassava Leaf Disease Detection Using Convolutional Neural Networks," in *2020 6th International Conference on Science in Information Technology: Embracing Industry 4.0: Towards Innovation in*

Disaster Management, ICSITech 2020, Institute of Electrical and Electronics Engineers Inc., Oct. 2020, pp. 97–102. doi: 10.1109/ICSITech49800.2020.9392051.

- [8] D. Darmawan *et al.*, “Metode Penelitian Kuantitatif,” 2024.
- [9] K. Maharana, S. Mondal, and B. Nemade, “A review: Data pre-processing and data augmentation techniques,” *Global Transitions Proceedings*, vol. 3, no. 1, pp. 91–99, Jun. 2022, doi: 10.1016/j.gltp.2022.04.020.
- [10] D. Irfan, R. Rosnelly, M. Wahyuni, J. T. Samudra, and A. Rangga, “Perbandingan Optimasi SGD, ADADELTA, dan ADAM dalam Klasifikasi Hydrange Menggunakan CNN,” 2022. [Online]. Available: <http://jurnal.goretanpena.com/index.php/JSSR>
- [11] M. Grandini, E. Bagli, and G. Visani, “Metrics for Multi-Class Classification: an Overview,” Aug. 2020, [Online]. Available: <http://arxiv.org/abs/2008.05756>