



Klasifikasi Penyakit Daun Tanaman Cengkeh Menggunakan Arsitektur MobileNetV2 Berbasis Web

Made Wahyu sudharma^{1*}, Ni Luh Putu Ika Candrawengi²

¹⁻² Teknologi Informasi, Universitas Pendidikan Nasional, Indonesia

E-mail: wahyusudharma16@gmail.com¹, Ikacandrawengi@undiknas.ac.id²

*Penulis Korespondensi: wahyusudharma16@gmail.com

Abstract. The clove plantation sector (*Syzygium aromaticum*) in Indonesia plays an important role in supporting national economic stability. However, its productivity faces threats from Plant Pest Organisms (PPOs), such as Clove Leaf Cacar Disease (CDC), Sooty Mold, and Dieback, which can cause losses of 10%-40% of total harvest yields. Conventional visual diagnosis is prone to subjectivity and human error, while the implementation of large-scale deep learning models is constrained by the computational capacity of end-user devices. This study aims to develop an objective and lightweight diagnostic system through the CloveVision web application based on the MobileNetV2 architecture. The study employed a quantitative experimental approach involving data collection, image preprocessing, model development using transfer learning and fine-tuning, system conversion, and evaluation. The dataset consisted of 1,000 clove leaf images collected from Tajun Village, Buleleng, Bali, with 250 images per class. The model was converted to TensorFlow.js to facilitate client-side execution directly in a web browser. The test results showed an accuracy of 78.75% on an independent test dataset, a model size of 9.24 MB, and an inference time of less than 100 milliseconds without an internet connection. Black-box testing achieved a 100% success rate, while usability testing using the System Usability Scale (SUS) with 15 farmers produced an average score of 86.67 (Best Imaginable). The study concludes that MobileNetV2 effectively balances accuracy and computational efficiency to support smart farming.

Keywords: Client-Side Execution; Clove; MobileNetV2; System Usability Scale; TensorFlow.js.

Abstrak. Sektor perkebunan cengkeh (*Syzygium aromaticum*) di Indonesia berperan penting dalam menopang stabilitas ekonomi nasional. Namun, produktivitasnya menghadapi ancaman Organisme Pengganggu Tumbuhan (OPT), seperti Cacar Daun Cengkeh (CDC), Embun Jelaga, dan Mati Pucuk, yang dapat menyebabkan kerugian 10%-40% hasil panen. Diagnosis visual konvensional rentan terhadap subjektivitas dan *human error*, sementara penerapan *deep learning* berskala besar terkendala kapasitas komputasi perangkat pengguna. Penelitian ini bertujuan mengembangkan sistem diagnosis objektif dan ringan melalui aplikasi web CloveVision berbasis arsitektur MobileNetV2. Penelitian menggunakan pendekatan eksperimental kuantitatif melalui tahapan pengumpulan data, pra-pemrosesan citra, pembangunan model dengan transfer learning dan fine-tuning, konversi sistem, serta evaluasi. Dataset terdiri atas 1.000 citra daun cengkeh dari Desa Tajun, Buleleng, Bali, dengan 250 citra per kelas. Model dikonversi ke TensorFlow.js untuk *client-side execution* pada web browser. Hasil pengujian menunjukkan akurasi 78,75% pada data uji independen, ukuran model 9,24 MB, dan waktu inferensi di bawah 100 milidetik tanpa koneksi internet. Black box testing mencapai keberhasilan 100%, sedangkan pengujian SUS terhadap 15 petani menghasilkan skor 86,67 (*Best Imaginable*). Penelitian menyimpulkan bahwa MobileNetV2 efektif menyeimbangkan akurasi dan efisiensi komputasi untuk mendukung smart farming.

Kata Kunci: Cengkeh; Eksekusi Sisi Klien; MobileNetV2; Skala Kegunaan Sistem; TensorFlow.js.

1. PENDAHULUAN

Sektor perkebunan secara konsisten memegang peranan yang sangat vital dan strategis dalam menopang stabilitas roda perekonomian nasional di Indonesia. Di antara berbagai jenis tanaman perkebunan yang ada, cengkeh (*Syzygium aromaticum*) menempati posisi yang sangat istimewa sebagai salah satu komoditas rempah bernilai ekonomi tinggi yang pemanfaatannya mencakup skala industri yang luas, mulai dari industri rokok kretek, sektor farmasi, hingga industri kosmetik (Syarifah et al., 2025). Meskipun Indonesia secara global telah dikenal luas sebagai produsen cengkeh terbesar di dunia, stabilitas dan tingkat produktivitas komoditas ini

terus-menerus dihadapkan pada tekanan besar yang bersumber dari ancaman Organisme Pengganggu Tumbuhan (OPT) (Nanja & Kamaruddin, 2023). Serangan patogen dan hama ini tidak boleh diremehkan, mengingat estimasi total kerugian akibat adanya serangan penyakit pada area-area perkebunan yang bersifat endemik dilaporkan dapat mencapai angka yang signifikan, yaitu berkisar antara 10% hingga 40% dari keseluruhan total hasil panen para petani (Khoiruddin et al., 2022). Dampak nyata dari ancaman patogen ini salah satunya terefleksi secara jelas melalui data resmi yang dirilis oleh Badan Pusat Statistik (BPS) Kabupaten Buleleng, yang memperlihatkan adanya fluktuasi produksi cengkeh yang cukup nyata dalam kurun waktu tiga tahun terakhir. Penurunan volume produksi yang sangat signifikan tercatat terjadi pada tahun 2023, di mana angka produksi merosot menjadi 2.073,40ton dari yang sebelumnya mampu mencapai 2.298,40ton pada tahun 2022. Kondisi penurunan produktivitas yang mengkhawatirkan ini sangat dirasakan langsung di sentra-sentra perkebunan rakyat, seperti halnya di Desa Tajun, Kecamatan Kubutambahan, Kabupaten Buleleng, di mana serangan patogen berbahaya pada organ daun tanaman menjadi salah satu faktor determinan utama di balik penurunan hasil panen tersebut. Secara umum, beberapa jenis penyakit infeksius yang paling sering dijumpai menyerang permukaan daun cengkeh di lapangan meliputi Cacar Daun Cengkeh (CDC), Embun Jelaga, serta penyakit Mati Pucuk (Mailuhu et al., 2024). Tantangan paling krusial yang dihadapi di lapangan adalah adanya tingkat kemiripan gejala visual yang sangat tinggi pada fase-fase awal infeksi patogen, sehingga menyulitkan para petani lokal untuk membedakan jenis penyakit secara tepat dan akurat. Terlebih lagi, metode konvensional yang selama ini diandalkan masih berbasis pada pengamatan visual mata manusia yang sangat rentan terhadap subjektivitas personal serta risiko *human error*, yang diperparah oleh adanya kesenjangan ketersediaan tenaga penyuluh pertanian profesional di wilayah-wilayah perkebunan terpencil.

Guna mengatasi keterbatasan pemantauan konvensional tersebut, kemajuan mutakhir di bidang teknologi kecerdasan buatan (*artificial intelligence*), khususnya melalui pendekatan *Deep Learning* dengan arsitektur *Convolutional Neural Network* (CNN), hadir menawarkan sebuah alternatif solusi diagnosis yang objektif dan terukur. Kemampuan utama dari model CNN terletak pada kapasitasnya untuk mengekstraksi fitur-fitur visual dari citra objek secara otomatis dan hierarkis tanpa menuntut tahapan rekayasa fitur manual yang rumit, sebuah keunggulan yang telah terbukti efektivitasnya dalam memecahkan masalah klasifikasi penyakit tanaman pada berbagai studi terdahulu (Panjaitan & Simatupang, n.d.). Dalam ranah klasifikasi citra pertanian sendiri, banyak penelitian sebelumnya telah mengeksplorasi penggunaan berbagai macam variasi arsitektur model *deep learning*. Salah satu arsitektur yang populer


digunakan adalah InceptionV3, yang dikenal memiliki kemampuan mumpuni dalam mengumpulkan serta mengekstraksi data visual dalam skala yang besar (Arifin Nur et al., 2025). Kelemahan utama dari arsitektur InceptionV3 adalah kebutuhan sumber daya komputasinya yang sangat besar (*computationally expensive*), sehingga pada implementasi praktis di masa lalu, model dengan arsitektur yang berat seperti ini sering kali dipaksakan untuk berjalan pada perangkat keras pengguna akhir (*end-user*) yang memiliki spesifikasi komputasi dan kapasitas daya yang sangat terbatas (Rosero-Montalvo et al., 2024). Adanya keterbatasan efisiensi pada model-model berat tersebut membuka sebuah celah riset yang mendasar bagi penelitian ini untuk menghadirkan sebuah pendekatan komputasi yang jauh berbeda dan lebih efisien. Sebagai bentuk jalan keluar atas kendala keterbatasan komputasi tersebut, penelitian ini memilih arsitektur MobileNetV2 sebagai tulang punggung (*backbone*) utama dari model klasifikasi yang dibangun. MobileNetV2 terbukti memiliki keunggulan komparatif yang sangat tinggi dalam menyeimbangkan antara performa akurasi klasifikasi dan efisiensi pemrosesan komputasi berkat integrasi mekanisme *Depthwise Separable Convolution* serta penerapan *Inverted Residual Block* (Alfan & Kumalasari, 2026). Karakteristik struktur model yang sangat ringan dan efisien ini menjadikan arsitektur MobileNetV2 sangat ideal untuk diimplementasikan langsung ke dalam sebuah sistem aplikasi berbasis web, yang dirancang agar dapat berjalan secara mandiri langsung di dalam *web browser* pada perangkat pengguna tanpa membebani kinerja ataupun memori server (Rahman et al., 2026). Sistem yang berhasil dikembangkan dalam penelitian ini dinamakan CloveVision, sebuah platform yang mengintegrasikan keandalan model CNN MobileNetV2 dengan *framework* React melalui pemanfaatan pustaka TensorFlow.js. Kehadiran CloveVision ini pada gilirannya memungkinkan para petani untuk melakukan diagnosis penyakit pada daun cengkeh secara mandiri, efisien, serta instan langsung dari area lahan pertanian.

Namun, keunggulan performa teknis dari model klasifikasi deep learning baru saja menyelesaikan satu aspek masalah yang ada. Aspek yang lebih penting adalah bagaimana teknologi tersebut dapat diterima dengan baik oleh pengguna akhir di lapangan. Sektor pertanian sering kali menemui hambatan besar dalam proses adopsi teknologi baru akibat rancangan antarmuka aplikasi yang terlalu kompleks, beban memori komputasi yang tinggi, serta ketergantungan mutlak pada kestabilan koneksi jaringan internet (Yunianto & Wahyudi, 2024). Sistem CloveVision yang dibangun ini tidak hanya berfokus pada peningkatan efisiensi komputasi model semata, melainkan juga berkomitmen memastikan aspek aksesibilitas yang inklusif bagi seluruh lapisan petani. Melalui pendekatan ini, para petani cengkeh dapat melakukan diagnosis penyakit tanaman secara mandiri lewat perangkat telepon seluler mereka

masing-masing tanpa harus menginstal aplikasi tambahan yang berpotensi membebani memori penyimpanan perangkat. Penerapan teknologi ini diharapkan dapat memberikan nilai guna serta kebermanfaatan yang nyata bagi para pengguna di lapangan, sekalipun mereka memiliki tingkat literasi digital yang beragam. Keberhasilan implementasi praktis ini diwujudkan melalui perancangan desain antarmuka pengguna yang mudah digunakan serta minimalis, yang menjamin bahwa seluruh proses identifikasi penyakit daun cengkeh dapat diselesaikan melalui alur kerja yang sangat efisien.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental dengan metode kuantitatif untuk mengembangkan dan mengevaluasi sistem klasifikasi penyakit daun cengkeh. Alur penelitian mencakup lima tahap utama yang berurutan, yaitu: (1) perencanaan dan pengumpulan data, (2) pra-pemrosesan citra, (3) pembangunan model *deep learning*, (4) konversi dan integrasi sistem web, serta (5) evaluasi dan validasi komprehensif.



Gambar 1. Alur Penelitian.

Pengumpulan Data

Data primer berupa citra digital daun cengkeh dikumpulkan secara langsung dari tiga kebun milik petani setempat di Desa Tajun, Kecamatan Kubutambahan, Kabupaten Buleleng, Bali. Pengambilan gambar dilakukan menggunakan kamera smartphone dengan standar teknis yang ketat: setiap sampel daun diletakkan di atas latar belakang berwarna netral untuk

meminimalkan gangguan visual (*noise*), dengan pencahayaan alami yang memadai dan sudut pengambilan tegak lurus terhadap objek daun (*top-down view*).



Gambar 2. Daun Cengkeh.

Seluruh citra dikategorikan secara manual ke dalam empat kelas kondisi daun berdasarkan karakteristik patologi yang dirujuk dari literatur ilmiah dan divalidasi oleh pakar lapangan. Total dataset yang berhasil dihimpun berjumlah 1.000 citra dengan distribusi yang seimbang, masing-masing 250 citra per kelas.


Pra-Pemrosesan Data

Sebelum memasuki fase pelatihan, seluruh citra melewati serangkaian prosedur pra-pemrosesan untuk memastikan konsistensi format dan kualitas data masukan. Proses ini dimulai dengan data cleaning untuk menyingkirkan citra yang buram, rusak, atau memiliki gangguan visual ekstrem. Selanjutnya, seluruh citra diubah ukurannya (*resizing*) menjadi resolusi standar 224×224 piksel, sesuai dengan spesifikasi input arsitektur MobileNetV2 (Tamayasa & Dewi, 2026). Normalisasi nilai piksel dilakukan dengan mengkonversi rentang integer $[0, 255]$ ke rentang desimal $[0, 1]$ menggunakan pembagian sederhana ($\frac{x}{255}$). Langkah ini bertujuan mempercepat konvergensi gradien selama pelatihan dan mencegah instabilitas numerik. Augmentasi data diterapkan secara dinamis khusus pada data latih menggunakan teknik pembalikan horizontal/vertikal (*flip*), rotasi, perbesaran (*zoom*), dan penyesuaian kecerahan untuk memperkaya variasi dataset dan meningkatkan kemampuan generalisasi model terhadap kondisi lapangan yang beragam (Alomar et al., 2023).

Arsitektur dan Pembangunan Model

Proses pembangunan model dalam penelitian ini berfokus pada pemanfaatan arsitektur *Deep Learning* yang efisien untuk klasifikasi citra. Model yang dipilih harus mampu menyeimbangkan antara akurasi yang tinggi dan beban komputasi yang ringan agar optimal saat diimplementasikan. Arsitektur MobileNetV2 dipilih sebagai basis utama karena keunggulannya dalam memproses data citra dengan jumlah parameter yang lebih sedikit melalui struktur *inverted residuals* dan *linear bottlenecks* (Husnurrizqi et al., 2026). Struktur

detail dan alur pemrosesan data dari input citra hingga menghasilkan prediksi kelas dapat dilihat pada Gambar 2 di bawah ini.



Gambar 3. Arsitektur MobileNetV2.

Model klasifikasi dibangun menggunakan arsitektur MobileNetV2 dengan pendekatan *transfer learning*. Bobot awal diperoleh dari model yang telah dilatih pada dataset ImageNet, sehingga model sudah memiliki kemampuan dasar yang kuat dalam mengekstraksi fitur visual umum. Lapisan-lapisan dasar (*base layers*) dibekukan sementara kepala klasifikasi (*custom head*) yang baru dilatih. *Custom head* terdiri dari lapisan *Global Average Pooling*, *Dropout* (50%), *Dense* dengan aktivasi ReLU, dan *Dense* akhir dengan aktivasi *Softmax* untuk menghasilkan distribusi probabilitas pada empat kelas target. Setelah fase *transfer learning* stabil, proses *fine-tuning* dilakukan dengan membuka kunci beberapa lapisan teratas MobileNetV2 menggunakan *learning rate* yang sangat rendah. Hal ini memungkinkan model mengadaptasi representasi fiturnya secara spesifik terhadap karakteristik visual penyakit daun cengkeh. Dua mekanisme callback digunakan untuk menjaga stabilitas pelatihan Model *Checkpoint* untuk menyimpan bobot terbaik berdasarkan *val_accuracy*, dan *Early Stopping* dengan *patience* 10 epoch untuk mencegah *overfitting*.

Tabel 1. Konfigurasi Parameter Model.

Parameter	Nilai
Base Model	MobileNetV2 (ImageNet)
Ukuran Input Citra	$224 \times 224 \times 3$ piksel
Epoch Maksimal	20 epoch
Fungsi Loss	<i>Categorical Crossentropy</i>
Optimizer	Adam
Total Parameter Model	2.422.468
Parameter Terlatih (<i>Fine-Tuning</i>)	2.025.924
Jumlah Kelas Output	4 kelas

Konversi Model dan Implementasi Sistem Web

Model Keras yang telah terlatih dikonversi ke format TensorFlow.js menggunakan utilitas *tensorflowjs_converter* melalui tahap perantara *SavedModel*. Proses konversi ini menghasilkan berkas arsitektur (JSON) dan bobot biner (BIN) yang dioptimasi untuk browser. Implementasi antarmuka menggunakan *framework* React dengan *bundler* Vite untuk menghasilkan aplikasi web yang responsif dan berperforma tinggi.

Arsitektur CloveVision menerapkan paradigma *client-side execution*, di mana seluruh proses inferensi model berlangsung langsung di browser pengguna tanpa mengirimkan data gambar ke server eksternal. Pendekatan ini memberikan tiga keunggulan sekaligus latensi inferensi yang sangat rendah (di bawah 100 milidetik), perlindungan privasi data visual petani, dan kemampuan beroperasi di area dengan koneksi internet terbatas.

Metode Evaluasi

Evaluasi dilakukan secara berlapis mencakup tiga aspek. Pertama, kinerja model klasifikasi diukur menggunakan *Confusion Matrix* dan metrik turunannya seperti *Accuracy*, *Precision*, *Recall*, dan *F1-Score* (*Building of Informatics, Technology and Science (BITS)*, 2025):

Accuracy (Akurasi)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (i)$$

Keterangan:

TP = True Positive (prediksi benar untuk kelas positif)

TN = True Negative (prediksi benar untuk kelas negatif)

FP = False Positive (prediksi salah sebagai kelas positif)

FN = False Negative (prediksi salah sebagai kelas negatif)

Akurasi mengukur sejauh mana model memprediksi dengan benar baik untuk kelas positif maupun negatif dari keseluruhan data.

Precision (Presisi)

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

Presisi mengukur ketepatan model dalam mengklasifikasikan sampel sebagai positif dari total hasil prediksi positif.

Recall (Sensitivitas)

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

Recall mengukur kemampuan model dalam menemukan kembali seluruh sampel positif yang ada pada dataset.

F1-Score

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


F1-Score merupakan rata-rata harmonik antara *Precision* dan *Recall*, yang sangat berguna terutama jika terdapat ketidakseimbangan kelas (*imbalanced data*) dalam dataset. Kedua, fungsionalitas sistem web divalidasi menggunakan *Black Box Testing* pada delapan skenario pengujian yang mencakup navigasi, unggah citra, inferensi, dan tampilan hasil. Ketiga, kegunaan sistem diukur melalui *System Usability Scale* (SUS) yang melibatkan 15 responden petani cengkeh aktif di Desa Tajun.

3. HASIL DAN PEMBAHASAN

Pada bagian ini tidak hanya menyajikan hasil eksperimen tetapi juga memberikan analisis menyeluruh tentang bagaimana model deep learning yang telah dibangun berfungsi. Menggunakan kumpulan 1.000 gambar daun cengkeh, evaluasi performa model dilakukan dengan membagi 1.000 gambar ke dalam empat kelas kondisi daun. Kelas sehat memiliki 250 gambar (25%) dan tiga kelas kondisi daun sakit (terinfeksi penyakit atau hama berbeda) memiliki 750 gambar (75%), dengan masing-masing kelas sakit menerima porsi seimbang sebesar 250 gambar (25%). Untuk memastikan penilaian akhir adil, semua data ini dibagi menjadi data pelatihan (*training*), validasi (*validation*), dan pengujian (*testing*).

Hasil Pelatihan Model

Untuk mencapai performa terbaik, konfigurasi pelatihan diatur secara terstruktur, di mana bobot model awal yang telah dilatih pada dataset berskala besar digunakan sebagai basis, kemudian disesuaikan kembali dengan karakteristik unik dari data daun cengkeh yang mencakup variasi kondisi sehat dan sakit. Detail mengenai alur pelatihan, dinamika nilai akurasi, serta penurunan nilai *loss* selama proses iterasi disajikan pada Gambar 3 berikut ini.



Gambar 4. Grafik Kurva Nilai Akurasi dan Nilai Loss.

Hasil proses pelatihan dilaksanakan dalam dua fase bertahap. Pada fase transfer learning, hanya *custom head* yang dilatih sementara base layers MobileNetV2 dibekukan. Fase ini menghasilkan fondasi klasifikasi yang stabil hingga epoch ke-11. Selanjutnya, fase fine-tuning dilakukan dengan membuka kunci sejumlah lapisan teratas untuk penyesuaian fitur spesifik terhadap dataset cengkeh. Kurva Nilai Akurasi pada Grafik (a), training accuracy menunjukkan peningkatan konsisten hingga mencapai 92% di akhir epoch ke-22. Pada tahap Pelatihan Awal (epoch 1-11), validation accuracy meningkat signifikan hingga mencapai puncak di kisaran 85%. Namun, memasuki tahap *fine-tuning* (epoch 12-22), validation accuracy cenderung mengalami fluktuasi dan penurunan. Hal ini menunjukkan bahwa model mulai beradaptasi secara berlebihan (*over-specialized*) terhadap fitur spesifik pada data latih, yang berimplikasi pada penurunan kemampuan generalisasi model pada data validasi. Sedangkan kurva Nilai Loss Pada Grafik (b), training loss menunjukkan penurunan stabil di kedua tahap, menandakan model terus mempelajari pola dari data latih dengan baik. Sementara itu, validation loss pada tahap Pelatihan Awal menurun tajam hingga mencapai titik terendah pada epoch 6-7. Setelah memasuki fase *fine-tuning*, *validation loss* justru mengalami kenaikan perlahan. Fenomena ini mengonfirmasi adanya gejala *overfitting*, di mana model menjadi terlalu spesifik terhadap data latih sehingga performa pada data validasi menurun. Model menunjukkan kemampuan konvergensi yang baik pada tahap awal. Meskipun terjadi gejala *overfitting* pada tahap *fine-tuning*, penggunaan *early stopping* tetap menjadi opsi terbaik untuk mempertahankan akurasi validasi tertinggi sebelum model kehilangan kemampuan generalisasinya.

Evaluasi Kinerja Model pada Data Uji


Model final diuji menggunakan 100 citra independen dari test set yang tidak pernah diikutsertakan dalam proses pelatihan maupun validasi. Hasil evaluasi komprehensif disajikan pada Tabel 2.

Tabel 2. Laporan Klasifikasi Model Final.

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Cacar Daun	0,67	0,62	0,65	25
Daun Sehat	0,74	1,00	0,85	25
Embun Jelaga	0,85	0,89	0,87	25
Mati Pucuk	0,89	0,64	0,74	25
Accuracy			0,79	100
Macro Avg	0,79	0,79	0,78	100

Berdasarkan Tabel 2, model menunjukkan tingkat akurasi keseluruhan sebesar 0,79 atau 79% dalam mengklasifikasikan kondisi daun cengkeh ke dalam empat kategori yang pertama Daun Sehat yaitu Memiliki performa deteksi terbaik dengan nilai *recall* mencapai

1,00, yang berarti seluruh sampel pada kelas ini berhasil terdeteksi dengan tepat oleh model, serta memperoleh nilai *F1-score* sebesar 0,85. Kedua embun jelaga, Model memiliki *recall* yang tinggi sebesar 0,89, menunjukkan bahwa sebagian besar sampel Embun Jelaga berhasil dideteksi dengan baik. Nilai *precision* sebesar 0,85 menunjukkan bahwa sebagian kecil prediksi Embun Jelaga masih merupakan salah klasifikasi dari kelas lain. Secara keseluruhan, nilai *F1-score* sebesar 0,87 mengindikasikan bahwa model memiliki performa yang baik dan seimbang dalam mengenali kelas Embun Jelaga. Ketiga mati pucuk yaitu Model memiliki *precision* yang tinggi sebesar 0,89, menunjukkan bahwa ketika model memprediksi kelas ini, prediksinya sangat dapat dipercaya. Namun, nilai *recall* sebesar 0,64 mengindikasikan masih terdapat cukup banyak sampel Mati Pucuk yang belum terdeteksi dengan optimal, dan yang terakhir cacar daun merupakan kelas dengan performa terendah, dengan nilai *precision* 0,67, *recall* 0,62, dan *F1-score* 0,65. Hal ini menunjukkan tantangan model dalam membedakan karakteristik visual Cacar Daun dibandingkan kelas lainnya. Secara keseluruhan, *macro average* untuk *precision*, *recall*, dan *f1-score* berada pada kisaran 0,78-0,79, yang mengonfirmasi bahwa meskipun terdapat variasi performa antar kelas, model secara rata-rata mampu memberikan performa klasifikasi yang cukup baik untuk kebutuhan identifikasi penyakit daun cengkeh.




Gambar 5. Matrik Hasil Klasifikasi.

Hasil pengujian model MobileNetV2 pada klasifikasi penyakit daun cengkeh menghasilkan tingkat akurasi keseluruhan sebesar 78,75% (dibulatkan menjadi 79% pada laporan klasifikasi Tabel 2), di mana berdasarkan sinergi antara *confusion matrix* dan laporan

klasifikasi final, model menunjukkan kemampuan temukan-kembali (*Recall*) terbaik pada kelas Daun Sehat sebesar 1,00 dengan 20 sampel berhasil dikenali tanpa kesalahan, meskipun nilai ketepatannya (*Precision*) berada di angka 0,74 karena adanya 7 sampel dari kelas lain yang salah terprediksi sebagai daun sehat. Selanjutnya, performa yang paling stabil dan seimbang ditunjukkan oleh kelas Embun Jelaga dengan *F1-Score* mencapai 0,87 dan 17 sampel benar, diikuti oleh kelas Mati Pucuk yang memperoleh tingkat kepercayaan (*Precision*) tinggi sebesar 0,89 namun memiliki *Recall* rendah sebesar 0,64 akibat hanya 16 sampel yang terdeteksi dengan tepat sementara sisanya tersebar ke kelas lain. Kelas Cacar Daun terbukti menjadi tantangan diskriminasi fitur terbesar dengan performa paling rendah (*Precision* 0,67 dan *Recall* 0,62) karena hanya mengidentifikasi 10 sampel dengan benar akibat kompleksitas kemiripan warna dan tekstur visual dengan kelas penyakit lainnya. Sebagai kesimpulan dari kedua data ini, karakteristik model telah dievaluasi dengan sangat andal untuk mengidentifikasi patogen yang lolos dari pengamatan awal petani dan untuk mengurangi kekeliruan diagnosis akibat tumpang tindih fitur visual yang serupa. Meskipun demikian, dengan rata-rata macro *F1-score* 0,78 dan efisien, karakteristik model masih memerlukan pengayaan variasi data masa depan khusus untuk kelas Cacar Daun dan Mati Pucuk.

Implementasi Sistem CloveVision

Sistem CloveVision diimplementasikan sebagai aplikasi web responsif dengan tiga modul halaman utama yang terintegrasi dapat dilihat pada gambar 6 tampilan webapp.



Gambar 6. Tampilan WebApp.

Tampilan *WebApp* yang disajikan pada Gambar 6 dirancang dengan struktur navigasi yang intuitif untuk memaksimalkan pengalaman pengguna dalam melakukan deteksi penyakit tanaman cengkeh secara efisien. Halaman Beranda berfungsi sebagai portal pengenalan utama yang menjelaskan urgensi pentingnya deteksi dini, sekaligus menyediakan tombol aksi cepat untuk langsung mengakses fitur klasifikasi. Selanjutnya, Halaman Identifikasi bertindak

sebagai inti operasional sistem, di mana pengguna dapat mengunggah citra daun dengan fleksibilitas menggunakan *file picker* atau kamera perangkat langsung dari antarmuka. Sistem kemudian akan memberikan hasil diagnosis berupa label kelas penyakit serta persentase *confidence score* secara dinamis di halaman yang sama, sehingga proses deteksi menjadi lebih praktis tanpa perlu sering berpindah halaman. Sebagai pelengkap, Halaman Informasi tersedia untuk memberikan wawasan edukatif kepada pengguna mengenai karakteristik detail serta gejala klinis dari setiap kelas penyakit yang dikategorikan oleh sistem, sehingga membantu pengguna dalam memahami kondisi kesehatan tanaman mereka dengan lebih baik.

Hasil Pengujian *Black Box Testing*

Pengujian fungsionalitas sistem dilakukan menggunakan metode *black box testing* yang berfokus pada validasi perilaku eksternal sistem tanpa memeriksa struktur kode internal. Delapan skenario pengujian mencakup: sistem navigasi, tombol aksi utama, modul unggah foto, pratinjau citra, trigger inferensi, tampilan hasil klasifikasi, modul informasi penyakit, dan tombol reset. Seluruh delapan skenario berhasil dieksekusi dengan status Sukses, menghasilkan tingkat keberhasilan fungsional sebesar 100% bisa dilihat pada table 3.

Tabel 3. Pengujian *Black Box* Aplikasi CloveVision.

No	Skenario Pengujian	Hasil yang Diharapkan	Status
1	Navigasi Sistem	Halaman berpindah sesuai dengan menu yang dipilih.	Sukses
2	Tombol Aksi Utama	Fungsi eksekusi berjalan tanpa kendala.	Sukses
3	Modul Unggah Foto	Sistem berhasil menerima format gambar yang valid.	Sukses
4	Pratinjau Citra/Tampilan Citra daun	Gambar yang diunggah muncul di layar pratinjau.	Sukses
5	Tombol Deteksi Penyakit	Proses pemrosesan model klasifikasi berjalan.	Sukses
6	Tampilan Hasil Klasifikasi	Output prediksi muncul sesuai dengan input.	Sukses
7	Modul Informasi Penyakit	Deskripsi Daun ditampilkan dengan akurat.	Sukses
8	Tombol Reset	Seluruh input dan output kembali ke kondisi awal.	Sukses

Hasil Pengujian *System Usability Scale (SUS)*

Pengujian kegunaan melibatkan 15 responden petani cengkeh aktif di Desa Tajun dengan karakteristik dominan berusia di atas 44 tahun dan pengalaman bertani antara 8 hingga 26 tahun. Setiap responden diminta mengoperasikan sistem secara mandiri sebelum mengisi kuesioner SUS yang terdiri dari 10 pernyataan dengan skala *Likert* 1-5.

Tabel 4. Rekapitulasi Jawaban Kuesioner SUS.

No	Pernyataan	STS	TS	N	S	SS
P1	Sering menggunakan sistem ini	0	1	4	10	0
P2	Sistem terlalu rumit	0	10	5	0	0
P3	Sistem mudah digunakan	0	1	3	11	0
P4	Perlu bantuan teknis	1	3	8	3	0
P5	Fungsi terintegrasi dengan baik	0	0	3	12	0
P6	Sistem ini tidak konsisten.	0	11	4	0	0
P7	Sistem ini mudah dipelajari.	0	0	5	10	0
P8	Sistem ini merepotkan.	0	12	3	0	0
P9	Saya percaya diri saat menggunakannya.	0	1	11	3	0
10	Saya perlu banyak belajar sebelum memakainya.	3	4	8	0	0

Berdasarkan hasil jawaban kuesioner pada Tabel 4, respons petani menunjukkan konsistensi yang sangat baik terhadap kemudahan penggunaan sistem. Hal ini terlihat dominan pada pernyataan positif seperti P3 (Sistem mudah digunakan) dan P7 (Sistem ini mudah dipelajari), di mana mayoritas responden memberikan nilai Setuju. Di sisi lain, pada pernyataan negatif seperti P2 (Sistem terlalu rumit) dan P8 (Sistem ini merepotkan), responden cenderung memberikan nilai Tidak Setuju. Hal ini mengonfirmasi bahwa desain antarmuka CloveVision tidak memberikan beban kognitif yang berlebih bagi pengguna, meskipun sebagian besar responden berada pada kelompok usia di atas 44 tahun. Namun, pada pernyataan P4 (Perlu bantuan teknis) dan P10 (Saya perlu banyak belajar sebelum memakainya), terdapat variasi jawaban pada skala Netral.

Perhitungan skor SUS mengikuti prosedur standar skor item bernomor ganjil (pernyataan positif) dihitung dengan mengurangi 1 dari nilai jawaban responden, sedangkan skor item bernomor genap (pernyataan negatif) dihitung dengan mengurangi nilai jawaban dari 5. Total skor seluruh item dijumlahkan lalu dikalikan 2,5 untuk menghasilkan skor akhir dalam rentang 0 - 100 (Handayani & Maria, n.d.). Berdasarkan perhitungan terhadap data 15 responden, diperoleh skor SUS rata-rata sebesar 86,67. Nilai ini berada jauh di atas ambang batas minimal penerimaan (skor 68) dan masuk ke dalam kategori Best Imaginable berdasarkan skala interpretasi standar SUS. Capaian ini mengindikasikan bahwa antarmuka CloveVision yang dirancang secara intuitif berhasil dioperasikan dengan baik.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi penyakit daun cengkeh berbasis web bernama CloveVision menggunakan arsitektur MobileNetV2 dengan pendekatan transfer *learning* dan *fine-tuning*. Model yang dikembangkan mampu mengklasifikasikan empat kelas kondisi daun Cacar Daun, Daun Sehat, Embun Jelaga, dan Mati Pucuk dengan akurasi uji sebesar 78,75% pada 100 citra independen. Implementasi model ke dalam format TensorFlow.js dan integrasi dengan *framework* React menghasilkan aplikasi web yang mampu melakukan inferensi secara instan di sisi klien dengan ukuran model hanya 9,24 MB. Paradigma *client-side execution* ini mengeliminasi ketergantungan pada koneksi internet yang stabil, sebuah keunggulan krusial bagi pengguna di wilayah perkebunan terpencil. Evaluasi komprehensif membuktikan keandalan sistem dari dua dimensi: pengujian *black box testing* mencatat tingkat keberhasilan fungsional 100%, sementara pengujian kegunaan dengan SUS menghasilkan skor 86,67 (kategori *Best Imaginable*). Penelitian ini membuktikan bahwa MobileNetV2 merupakan pilihan arsitektur yang tepat untuk skenario smart farming yang

memprioritaskan efisiensi dan aksesibilitas di atas akurasi absolut. Pengembangan ke depan dapat difokuskan pada perluasan dataset dan penambahan fitur rekomendasi penanganan berbasis hasil diagnosis.

DAFTAR REFERENSI

- Alfan, D. S., & Kumalasari, I. (2026). Implementasi model deep learning MobileNetV2 untuk klasifikasi citra melanoma berbasis web. 7(3).
- Alomar, K., Aysel, H. I., & Cai, X. (2023). Data augmentation in classification and segmentation: A survey and new strategies. *Journal of Imaging*, 9(2), 46. <https://doi.org/10.3390/jimaging9020046>
- Arifin Nur, K. N., Wanto, A., Windarto, A. P., & Solikhun, S. (2025). Model deep learning berbasis Inception V3 untuk klasifikasi penyakit daun apel menggunakan citra digital. *Journal of Computer System and Informatics (JoSYC)*, 6(3), 591–600. <https://doi.org/10.47065/josyc.v6i3.7003>
- Building of Informatics, Technology and Science (BITS)*. (2025). 7(3).
- Handayani, R., & Maria, E. (n.d.). Usability aplikasi GrabMerchant: Evaluasi dengan metode System Usability Scale dan retrospective think aloud. 14.
- Husnurizqi, H. A., Kurnia, D. A., Wijaya, Y. A., & Dikananda, F. (2026). Klasifikasi citra menggunakan arsitektur MobileNetV2 dengan pendekatan transfer learning. *Artificial Intelligence*, 3(3).
- Khoiruddin, M., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi penyakit daun padi menggunakan convolutional neural network. *Data Science*, 1.
- Mailuhu, D., Patty, J., Tuhumury, G. N. C., Kewilaa, V. L. N., & Sarfan, R. (2024). Kerusakan tanaman cengkeh (*Syzygium aromaticum*) akibat serangan penyakit di Kecamatan Saparua. *AGROLOGIA: Jurnal Ilmu Budidaya Tanaman*, 13(2), 175–183. <https://doi.org/10.30598/agrologia.v13i2.15591>
- Nanja, M., & Kamaruddin, A. (2023). Sistem cerdas diagnosa organisme pengganggu tanaman cengkeh menggunakan metode Bayes. 5(3).
- Panjaitan, G. H. A., & Simatupang, F. (n.d.). *Pemodelan klasifikasi penyakit daun tanaman tomat dengan convolutional neural network algorithm*.
- Rahman, R., Maharani, S., Toni, M. I., Rizal, K., & Hidayat, R. (2026). Implementasi MobileNetV2 untuk aplikasi edukasi sejarah Monumen Nasional berbasis [judul tidak lengkap]. 11(1).
- Rosero-Montalvo, P. D., Tözün, P., & Hernandez, W. (2024). Optimized CNN architectures benchmarking in hardware-constrained edge devices in IoT environments. *IEEE Internet of Things Journal*, 11(11), 20357–20366. <https://doi.org/10.1109/JIOT.2024.3369607>
- Syarifah, A. A., Sidhi, E. Y., Lisanty, N., & Pamujiati, A. D. (2025). Rantai nilai agribisnis komoditas cengkeh di Kabupaten Trenggalek. *Jurnal Agro Industri Perkebunan*, 13(2), 125–140. <https://doi.org/10.25181/jaip.v13i2.4133>

- Tamayasa, K. A., & Dewi, L. J. E. (2026). Analisis perbandingan model arsitektur MobileNetV2 dan EfficientNetB3 dalam klasifikasi penyakit daun jagung. *Jurnal Informatika dan Teknik Elektro Terapan*, 14(1). <https://doi.org/10.23960/jitet.v14i1.8624>
- Yunianto, I., & Wahyudi, W. (2024). Designing user experience for a mobile application for agricultural product marketing using the human-centered design method. *International Journal of Graphic Design*, 2(2), 207–221. <https://doi.org/10.51903/ijgd.v2i2.2123>