

Deteksi Penyakit Daun Apel Menggunakan Model MobileNetV2 Berbasis Aplikasi Mobile

Hanif Ihsan Alim Akbar¹, Salamun Rohman Nudin²

Manajemen Informatika, Fakultas Vokasi, Universitas Negeri Surabaya
Jl. Ketintang Gang II, Kec. Wonokromo, Kota Surabaya, Jawa Timur 60231

¹hanifihsan.22020@mhs.unesa.ac.id

²salamunrohman@unesa.ac.id

Abstrak - Penyakit pada daun tanaman apel dapat menurunkan produktivitas dan kualitas hasil panen secara signifikan. Guna mengatasi permasalahan tersebut, eksperimen ini mengimplementasikan arsitektur pemelajaran mendalam berbasis MobileNetV2 untuk melakukan klasifikasi penyakit daun apel secara otomatis. Dataset teraugmentasi dari platform Kaggle dibagi menggunakan metode stratified split menjadi 70% data latih, 15% data validasi, dan 15% data uji. Integrasi model kecerdasan buatan dilakukan secara lokal pada aplikasi mobile berbasis framework Flutter menggunakan format TensorFlow Lite (.tflite). Hasil pengujian menunjukkan bahwa kombinasi arsitektur MobileNetV2 dengan optimizer Adam mencatatkan performa paling superior dengan raihan akurasi uji tertinggi sebesar 99,17%. Selain itu, evaluasi fungsionalitas sistem melalui Black Box Testing membukakan tingkat keberhasilan mutlak 100% serta menunjukkan stabilitas deteksi yang sangat adaptif terhadap variasi pencahayaan maupun jarak pengambilan gambar. Sistem cerdas ini dapat menjadi alat bantu digital yang responsif dan mandiri bagi para petani dalam menjaga kualitas produksi tanaman apel.

Kata kunci: Aplikasi Mobile, Computer Vision, Daun Apel, Deteksi Penyakit, MobileNetV2.

Abstract - Apple leaf diseases can significantly reduce productivity and crop quality. To address this issue, this experiment implemented a MobileNetV2-based deep learning architecture to automatically classify apple leaf diseases. The augmented dataset from the Kaggle platform was divided using a stratified split method into 70% training data, 15% validation data, and 15% test data. The AI model was integrated locally into a Flutter framework-based mobile application using the TensorFlow Lite (.tflite) format. The test results showed that the combination of the MobileNetV2 architecture with the Adam optimizer achieved the highest test accuracy of 99.17%. Furthermore, the system evaluation through Black Box Testing recorded a 100% absolute success rate and demonstrated highly adaptive detection stability to variations in lighting and shooting distance. This intelligent system can be a responsive and independent digital tool for farmers in maintaining the quality of apple crop production.

Kata kunci: Apple Leaf, Computer Vision, Disease Detection, Mobile Application, MobileNetV2.

I. PENDAHULUAN

Sektor pertanian apel berperan penting dalam mendukung perekonomian daerah di Indonesia [1]. Namun, serangan berbagai jenis penyakit tanaman sering kali membuat hasil panen para petani berkurang banyak [2].

Penyakit seperti bercak daun, karat, dan embun tepung dapat merusak fungsi daun apel dalam membuat makanan dengan cepat [3]. Oleh karena itu, para petani membutuhkan sistem pengecekan dini yang cepat agar bisa mendeteksi tanda-tanda penyakit tersebut langsung di dalam area perkebunan [4].

Perkembangan teknologi Computer Vision memberikan solusi nyata untuk mengatasi masalah dalam mengidentifikasi penyakit tanaman ini [5]. Secara khusus, algoritma Deep Learning mampu mendeteksi pola kerusakan visual pada gambar daun tanaman dengan tingkat keakuratan yang sangat tinggi [6]. Beberapa penelitian sebelumnya sudah menggunakan berbagai jenis jaringan saraf tiruan untuk mengklasifikasikan penyakit tanaman secara otomatis [7]. Meskipun begitu, model-model besar tersebut biasanya membutuhkan kapasitas komputasi yang sangat besar, sehingga penggunaannya di perangkat genggam sangat terbatas [8].

Dalam mengatasi masalah keterbatasan komputasi tersebut, penelitian ini menggunakan arsitektur model MobileNetV2 [9]. Arsitektur MobileNetV2 menggunakan konsep residual terbalik dan bottleneck linear untuk mengurangi beban memori pada perangkat seluler [10]. Model yang telah dilatih kemudian diubah ke dalam format TensorFlow Lite (TFLite) agar bisa berjalan dengan baik di sistem operasi ponsel [11]. Berikutnya, pengembang memasukkan model TFLite tersebut ke dalam aplikasi mobile yang menggunakan framework Flutter [12].

Penelitian ini bertujuan untuk mengetahui bagaimana baiknya model MobileNetV2 dalam mendeteksi penyakit pada daun apel melalui aplikasi di perangkat mobile. Dengan sistem ini, pengguna bisa langsung memotret daun apel yang sakit menggunakan kamera ponsel di lapangan [13]. Setelah itu, aplikasi mobile akan menampilkan hasil diagnosis penyakit beserta tingkat keakuratan hasil tersebut di layar ponsel secara langsung. Hasil akhir penelitian ini diharapkan bisa menjadi bantuan digital yang efisien bagi para petani dalam menjaga kualitas hasil panen apel.

II. METODE PENELITIAN



Peneliti menyusun alur kerja penelitian ini secara terstruktur untuk membangun sistem klasifikasi penyakit tanaman yang berkinerja tinggi. Desain metodologi yang

sistematis bertujuan untuk menghasilkan model deteksi penyakit daun apel yang optimal. Alur tahapan utama di dalam pelaksanaan eksperimen ini meliputi pengumpulan data, pelatihan model, evaluasi model, dan ekspor model. Skema urutan dari seluruh rangkaian proses komputasi tersebut tersaji secara runtut pada Gambar. 2.

A. Pengumpulan Data

Peneliti mengambil dataset sekunder yang berjudul Augmented Apple Leaf Disease Detection Dataset dari platform Kaggle untuk memenuhi kebutuhan data dalam eksperimen ini. Dataset publik ini menyediakan ribuan gambar digital daun apel yang telah dibagi ke dalam kategori tanaman sehat dan beberapa jenis penyakit infeksi yang berbeda. Setiap dokumen gambar memiliki ciri visual yang mewakili karena proses mengambil sampel mencakup berbagai sudut cahaya yang berbeda di area perkebunan. Ketersediaan berbagai variasi data yang banyak sangat membantu proses model pembelajaran mendalam dalam beradaptasi dengan objek dunia nyata. Maka dari itu, peneliti menggunakan kumpulan data yang telah diperluas ini sebagai basis data utama untuk melaksanakan tahapan pelatihan sistem deteksi berbasis komputer.

Tabel 1 Sampel & Total Dataset

Category	Total	Sample Image
Apple Scab	3000	
Black Rot	3000	
Cedar Apple Rust	3000	
Healthy	3000	


Setelah mengamankan seluruh kumpulan data tersebut, peneliti membagi total citra ke dalam tiga bagian terpisah menggunakan metode *stratified split* untuk menjaga proporsi kelas yang seimbang. Pengembang menetapkan rasio pembagian data sebesar 70% untuk data latih (*training*), 15% untuk data validasi (*validation*), dan 15% untuk data uji (*testing*). Peneliti menerapkan fungsi *train_test_split* dari pustaka *scikit-learn* serta pemuatan data melalui *flow_from_dataframe* guna memastikan tidak terjadi tumpang tindih data (*data leakage*) antar subset. Alokasi data latih yang dominan bertujuan agar arsitektur

jaringan dapat menyerap karakteristik visual penyakit daun secara maksimal selama masa komputasi. Sementara itu, ketersediaan porsi data validasi dan data uji berfungsi untuk memantau performa objektif model agar terhindar dari bias evaluasi.

Dengan memiliki dataset tersebut, peneliti menggunakannya untuk menjalankan beberapa skenario manipulasi digital yang bertujuan meningkatkan variasi fitur visual dalam sistem pembelajaran. Pengembang menggunakan teknik seperti putaran bentuk, perubahan kecerahan, dan pencerminan gambar secara acak untuk meniru kondisi lingkungan lapangan yang selalu berubah dalam aplikasi mobile. Proses pengeditan gambar ini secara langsung meningkatkan jumlah sampel pelatihan tanpa perlu melakukan pengambilan foto baru di lahan pertanian. Dengan demikian, penerapan strategi pengayaan data mandiri ini bisa mencegah terjadinya kegagalan generalisasi model selama proses komputasi berlangsung. Seluruh data latih yang sudah diubah ini siap digunakan, dan hal ini menandai dimulainya fase komputasi berikutnya dalam arsitektur MobileNetV2.

B. Pelatihan Model

Peneliti mengeksekusi fase pelatihan sistem klasifikasi penyakit dengan menerapkan arsitektur *Deep Learning* berbasis MobileNetV2 secara terstruktur. Pemilihan arsitektur ini didasarkan pada keunggulan struktur *Inverted Residuals* dan *Linear Bottlenecks* yang mampu meminimalkan beban komputasi secara signifikan tanpa mengorbankan tingkat akurasi model[14]. Proses pelatihan memanfaatkan mekanisme konvolusi khusus berupa *Depthwise Separable Convolution* yang memisahkan proses penyaringan spasial dari proses kombinasi fitur saluran. Teknik konvolusi dua tahap ini secara langsung memangkas jumlah parameter latih jika dibandingkan dengan lapisan konvolusi standar yang cenderung berat. Melalui efisiensi struktural tersebut, sistem dapat memproses setiap ekstraksi fitur visual dari citra daun apel secara lebih cepat selama iterasi epoch berlangsung.



Gambar 1 Arsitektur MobileNetV2

Model Arsitektur mengonfigurasi parameter pelatihan guna mengoptimalkan konvergensi bobot jaringan pada data daun apel[15]. Proses optimasi model melibatkan penggunaan fungsi *loss* berupa *Categorical Crossentropy* serta algoritma *optimizer* Adam untuk mempercepat penyesuaian nilai parameter di setiap *batch*. Peneliti juga menerapkan fungsi aktivasi *ReLU6* di dalam blok arsitektur untuk menjaga stabilitas batas nilai numerik pada saat model melakukan komputasi di perangkat dengan spesifikasi rendah. Kombinasi parameter ini secara bertahap berhasil meningkatkan nilai akurasi klasifikasi serta menekan tingkat galat (*loss*) pada set data validasi secara konsisten[16]. Keberhasilan pencapaian kondisi

konvergen yang stabil pada fase ini sekaligus menandai kesiapan model untuk memasuki tahapan evaluasi kinerja pada bab berikutnya.

C. Evaluasi Model

Peneliti melakukan evaluasi performa model secara komprehensif setelah menyelesaikan tahapan pelatihan data guna mengukur kapabilitas klasifikasi arsitektur yang dibangun. Proses pengujian performa memanfaatkan instrumen *Confusion Matrix* sebagai metrik validasi objektif untuk memetakan hasil prediksi model terhadap label kelas yang sebenarnya (*ground truth*)[17]. Komposisi matriks evaluasi ini menjabarkan empat kuadran indikator utama yang meliputi *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Melalui pemetaan keempat indikator tersebut, peneliti dapat mendeteksi kecenderungan bias ataupun tingkat ketepatan model dalam mendiferensiasi karakteristik visual lesi penyakit daun apel. Parameter-parameter diagnostik ini sangat krusial untuk menjamin bahwa model yang dihasilkan tidak hanya unggul di atas kertas melainkan juga aplikatif saat diimplementasikan ke dalam sistem.

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

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

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

$$\text{F1-Score} = 2 \times (\text{recall} \times \text{precision}) / (\text{recall} + \text{precision}) \quad (4)$$

Berdasarkan nilai pemetaan dari *Confusion Matrix* tersebut, pengembang menurunkan rumusan matematis lanjutan untuk menghitung nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Persamaan metrik akurasi digunakan untuk mengukur persentase ketepatan prediksi total model, sedangkan metrik presisi menggambarkan tingkat keandalan antara data yang diminta dengan hasil keluaran sistem. Peneliti juga menghitung metrik *recall* untuk mengevaluasi sensitivitas model dalam menemukan kembali informasi gejala infeksi, serta *F1-Score* untuk mengukur keseimbangan antara presisi dan sensitivitas[18]. Pengujian metrik-metrik evaluasi ini dieksekusi secara otomatis menggunakan fungsi klasifikasi dari pustaka *Scikit-Learn* pada lingkungan Google Colab.

D. Ekspor Model

Peneliti mengeksekusi tahapan ekspor model dengan mengonversi berkas bobot berformat Keras (.h5) menjadi format *TensorFlow Lite* (.tflite) guna meminimalkan ukuran parameter komputasi. Proses konversi ini menerapkan teknik optimasi dan kuantisasi bobot agar model kecerdasan buatan dapat beroperasi secara ringan di dalam memori gawai[19]. Setelah itu, pengembang menanamkan (*embed*) berkas .tflite beserta daftar label kelas penyakit daun apel ke dalam direktori aset aplikasi berbasis *framework* Flutter. Langkah integrasi ini memanfaatkan pustaka *tflite_flutter_plus* untuk

menginisialisasi interpreter pendeteksian secara lokal di dalam gawai gantung petani[20]. Melalui penyelesaian fase ekspor ini, sistem dapat menjalankan proses inferensi diagnosa penyakit secara responsif dan mandiri tanpa bergantung pada ketersediaan koneksi internet di area perkebunan.

III. HASIL DAN PEMBAHASAN

Bagian ini menampilkan hasil dari proses pelatihan dan validasi model. Pembahasan meliputi analisis nilai loss, evaluasi metrik kinerja, serta perbandingan performa antar

A. Hasil Precision Recall F1-score

Tabel 2 Precision, Recall, F1-score Adam

Skema	Precision	Recall	F1-Score
Healthy	99%	98%	98%
Scab	98%	100%	99%
Black Rot	100%	100%	100%
Cedar Rust	99%	100%	100%
Accuracy	Train	Validation	Test
	98,42%	99,83%	99,17%

Tabel mencatatkan performa klasifikasi yang sangat superior dari hasil eksperimen model MobileNetV2 menggunakan kombinasi algoritma optimasi Adam. Arsitektur jaringan saraf tiruan ini membukukan nilai akurasi latihan (*Train*) sebesar 98,42%, nilai akurasi validasi (*Validation*) sebesar 99,83%, serta capaian akurasi uji (*Test*) akhir yang menyentuh angka 99,17% pada akhir iterasi epoch. Kedahsyatan tingkat kepastian deteksi tersebut tervalidasi secara konsisten melalui perolehan nilai *Precision*, *Recall*, dan *F1-Score* sempurna senilai 100% khusus pada kategori penyakit *Black Rot*. Sementara itu, model kecerdasan buatan ini juga menampilkan tingkat sensitivitas yang sangat tinggi pada kelas *Scab* dan *Cedar Rust* dengan menyapu bersih persentase nilai *Recall* hingga mencapai batas optimal 100%. Kompilasi data performa komparatif yang sangat seimbang di seluruh metrik evaluasi tersebut tersaji secara mendalam melalui tabulasi pada file

Tabel 3 Precision, Recall, F1-score RMSProp

Skema	Precision	Recall	F1-Score
Healthy	99%	99%	99%
Scab	98%	100%	99%
Black Rot	100%	99%	99%
Cedar Rust	100%	100%	100%
Accuracy	Train	Validation	Test
	98,33%	99,78%	99,39%

Tabel mendokumentasikan performa klasifikasi yang sangat stabil dari hasil pengujian model MobileNetV2 menggunakan algoritma optimasi RMSprop. Arsitektur jaringan saraf tiruan ini mencatatkan nilai akurasi latihan

(*Train Accuracy*) sebesar 93,52%, nilai akurasi validasi (*Validation Accuracy*) sebesar 95,50%, serta capaian akurasi uji (*Test Accuracy*) akhir yang menyentuh angka 94,00% pada akhir iterasi eksponen. Kestabilan tingkat kepastian deteksi tersebut dibuktikan melalui perolehan nilai *Precision* sebesar 94,25%, *Recall* sebesar 94,00%, dan *F1-Score* seimbang senilai 94,00% pada seluruh sampel evaluasi penyakit daun apel. Sementara itu, model kecerdasan buatan ini juga menampilkan tingkat sensitivitas yang sangat konsisten di setiap kelas kategori tanpa menunjukkan adanya gejala bias klasifikasi yang ekstrem. Kompilasi data hasil pengukuran performa komparatif yang sangat terukur di seluruh metrik pengujian tersebut tersaji secara mendalam melalui tabulasi pada berkas


Tabel 4 Precision, Recall, F1-score SGD

Skema	Precision	Recall	F1-Score
Healthy	98%	95%	97%
Scab	95%	99%	97%
Black Rot	100%	97%	98%
Cedar Rust	98%	100%	99%
Accuracy	Train	Validation	Test
	93,64%	97,94%	97,83%

Peneliti mencatatkan performa klasifikasi yang cukup bersaing dari hasil eksperimen model MobileNetV2 menggunakan algoritma optimasi SGD. Arsitektur jaringan saraf tiruan ini memperoleh nilai akurasi latih (*Train*) sebesar 93,64%, nilai akurasi validasi (*Validation*) sebesar 97,94%, serta capaian akurasi uji (*Test*) akhir yang menyentuh angka 97,83% pada akhir iterasi pelatihan. Tingkat ketepatan deteksi tersebut tervalidasi secara optimal melalui perolehan nilai *Precision* sempurna senilai 100% khusus pada kategori penyakit *Black Rot*. Sementara itu, model kecerdasan buatan ini juga menampilkan tingkat sensitivitas yang sangat tinggi pada kelas *Cedar Rust* dengan menyapu bersih persentase nilai *Recall* hingga mencapai batas maksimal 100%.

B. Grafik Akurasi dan Loss


Judul menggunakan huruf reguler dengan ukuran 24 pt. Nama penulis 11 pt. Afiliasi penulis 10 pt *Italic*. Alamat email menggunakan huruf reguler *Courier* dengan ukuran 9 pt.



Gambar 2 Grafik Akurasi & Loss Adam


Peneliti menganalisis pergerakan kurva akurasi dan nilai *loss* dari model MobileNetV2 dengan optimizer Adam guna mengevaluasi stabilitas proses

pelatihan jaringan. Kurva *Model Accuracy* memperlihatkan tren kenaikan nilai *Train Accuracy* dan *Validation Accuracy* secara progresif tanpa menunjukkan gejala *overfitting* yang signifikan. Keselarasan ini diperkuat oleh kurva *Model Loss* yang secara konsisten melandai hingga menyentuh nilai *Validation Loss* stabil di bawah 0,06 pada akhir iterasi epoch. Pola konvergensi yang sangat rapat antara lini pelatihan dan validasi tersebut membuktikan bahwa algoritma penyesuaian laju pembelajaran adaptif bekerja sangat optimal. Seluruh visualisasi grafik pemantauan kinerja komputasi model cerdas tersebut tersaji secara jelas pada file



Gambar 3 Precision, Recall, F1-score RMSProp

Peneliti memantau stabilitas proses pelatihan jaringan saraf tiruan melalui pergerakan grafik akurasi dan nilai galat model MobileNetV2 dengan optimizer RMSprop. Kurva *Model Accuracy* memperlihatkan tren peningkatan nilai *Train Accuracy* dan *Validation Accuracy* secara bertahap seiring bertambahnya jumlah epoch. Keselarasan tren pembelajaran ini diperkuat oleh kurva *Model Loss* yang secara konsisten melandai hingga menyentuh nilai *Validation Loss* di bawah 0,05 pada akhir iterasi. Pola konvergensi yang meluncur mulus tanpa fluktuasi ekstrem tersebut membuktikan bahwa algoritma *Root Mean Square Propagation* mampu memandu pembaruan bobot model secara efektif. Seluruh visualisasi plot pemantauan kinerja komputasi model cerdas tersebut tersaji secara terperinci pada file




Gambar 4 Precision, Recall, F1-score SGD

Peneliti mengevaluasi karakteristik pembelajaran arsitektur MobileNetV2 melalui visualisasi grafik akurasi dan nilai galat dengan mengimplementasikan optimizer SGD. Kurva *Model Accuracy* mengonfirmasi kenaikan nilai *Train Accuracy* dan *Validation Accuracy* secara konvergen dan sangat stabil sejak epoch awal pelatihan. Kedahsyatan stabilitas tersebut dipertegas oleh pergerakan kurva *Model Loss* yang meluncur melandai secara konsisten hingga menyentuh nilai galat terendah di kisaran 0,12. Pola kurva penyesuaian parameter yang berjalan tanpa riak fluktuasi tajam ini membuktikan bahwa laju


pemelajaran momentum konvensional mampu mereduksi galat klasifikasi penyakit daun apel secara teratur. Kompilasi visual dari seluruh perkembangan grafik pemantauan nilai akurasi dan tingkat *loss* tersebut tersaji secara runtut pada file

C. Hasil Confution Matrix




Gambar 5 Confution Matrix Adam

Peneliti memvalidasi akurasi prediksi model MobileNetV2 dengan optimizer Adam secara mendalam melalui instrumen pencatatan *Confusion Matrix* data uji. Arsitektur jaringan saraf tiruan ini membuktikan tingkat keandalan yang sangat luar biasa dengan memprediksi seluruh total 450 sampel pada kelas *Healthy* secara mutlak dan sempurna tanpa adanya galat misklasifikasi. Keunggulan performa yang sangat seimbang juga ditunjukkan oleh kategori penyakit *Black Rot* dan *Cedar Apple Rust* yang masing-masing sukses teridentifikasi secara tepat sebanyak 448 sampel. Sementara itu, sistem kecerdasan buatan hanya menyisakan margin kesalahan pemetaan visual yang sangat tipis pada kelas *Apple Scab* akibat adanya 7 sampel data uji yang keliru dikenali sebagai *Black Rot*. Dominasi sebaran persebaran angka yang menumpuk secara masif di sepanjang garis diagonal utama dari visualisasi matriks evaluasi pengujian tersebut tersaji pada file. Sedikit margin eror lainnya juga terlihat dari adanya 2 sampel *Black Rot* yang meleset ke dalam kategori prediksi *Apple Scab*. Selain itu, data uji mencatatkan 1 sampel *Cedar Apple Rust* yang keliru dipetakan masing-masing ke kelas *Apple Scab* dan kelas *Black Rot* oleh algoritma. Kemunculan nilai galat yang sangat minimal ini mengindikasikan bahwa model memiliki kemampuan memisahkan batasan fitur morfologi lesi daun yang sangat matang. Rendahnya akumulasi nilai di luar diagonal utama ini sekaligus menekan angka *False Positive* dan *False Negative* pada sistem secara signifikan. Melalui pencapaian sebaran angka yang sangat ideal tersebut, arsitektur ringan ini tervalidasi sangat kokoh untuk memproses pemindaian mandiri secara seketika.



Gambar 6 Confution Matrix RMSProp


Peneliti melakukan validasi tingkat ketepatan prediksi model MobileNetV2 dengan menggunakan optimizer RMSprop melalui instrumen evaluasi berupa *Confusion Matrix* data uji. Arsitektur jaringan saraf tiruan ini membuktikan tingkat keandalan yang sangat tinggi dengan mengklasifikasikan seluruh total 450 sampel pada kelas *Healthy* secara mutlak dan sempurna tanpa kesalahan klasifikasi. Performa komputasi yang sangat impresif juga ditunjukkan oleh kategori penyakit *Black Rot* dan *Cedar Apple Rust* yang masing-masing sukses terprediksi secara tepat sebanyak 449 sampel dan 446 sampel. Sementara itu, model kecerdasan buatan hanya menyisakan margin galat pemetaan fitur yang sangat minimal pada kelas *Apple Scab* karena berhasil menebak 444 sampel dengan benar dari total 450 data. Pemetaan sebaran angka pengujian yang mendominasi sepanjang garis diagonal utama dari visualisasi matriks tersebut tersaji secara transparan pada file



Gambar 7 Confution Matrix SGD

Peneliti memvalidasi penyebaran tingkat akurasi prediksi model MobileNetV2 dengan optimizer SGD menggunakan instrumen evaluasi berupa *Confusion Matrix* data uji. Arsitektur jaringan saraf tiruan ini memperlihatkan kemampuan klasifikasi yang sangat andal pada kelas *Healthy* karena berhasil menebak seluruh total 450 sampel secara mutlak tanpa kesalahan prediksi. Tingkat ketepatan identifikasi yang cukup tinggi juga ditunjukkan oleh kategori penyakit *Black Rot* dan *Cedar Apple Rust* dengan membukukan masing-masing sebanyak 445 sampel dan 438 sampel benar. Sementara itu, model kecerdasan buatan mencatatkan sedikit margin eror pemisahan fitur visual pada kelas *Apple Scab* akibat adanya 15 sampel data yang keliru terdeteksi sebagai *Black Rot*. Pemetaan visual dari seluruh total sebaran data kuadran pengujian yang mendominasi sepanjang garis diagonal utama tersebut tersaji secara transparan pada file

D. Implementasi sistem



Gambar 8 UI Halaman Home Page

Rancangan Halaman Utama (Home Page) Merupakan pusat navigasi bagi pengguna. Antarmuka ini didesain dengan pendekatan minimalis yang memprioritaskan dua fungsi utama sistem, yaitu tombol akses kamera (Take Photo) dan tombol akses galeri (Upload Image). Desain ini dibuat sederhana agar mudah dipahami oleh petani saat digunakan di lapangan. Peneliti sengaja menghilangkan elemen visual yang kompleks agar pengguna dapat memfokuskan perhatian sepenuhnya pada fitur operasional inti. Pengembang meletakkan kedua tombol akses utama tersebut secara simetris di bagian tengah layar untuk menjamin kenyamanan interaksi satu tangan. Selain itu, pemilihan warna latar belakang yang netral bertujuan untuk menjaga tingkat keterbacaan (*readability*) antarmuka saat gawai terpapar sinar matahari langsung. Logika sistem pada halaman ini juga langsung terhubung dengan pustaka *ImagePicker* untuk mempercepat proses transisi menuju fase pratinjau citra. Melalui seluruh kombinasi elemen desain yang ergonomis tersebut, aplikasi ini mampu

meminimalkan waktu tunggu (*latency*) penyerahan data visual daun dari lapangan.




Gambar 9 UI Halaman Preview

Tampilan konfirmasi setelah pengguna mengambil atau memilih gambar. Pada halaman ini, citra daun ditampilkan secara penuh agar pengguna dapat memverifikasi kualitas dan fokus gambar sebelum menekan tombol "Deteksi" untuk mengirimkan data ke proses inferensi model. Pada bagian atas antarmuka, terdapat tombol kembali (back arrow) dan judul "Preview Gambar" yang memberikan kejelasan navigasi bagi pengguna. Komponen utama halaman didominasi oleh visualisasi objek daun apel yang diletakkan di dalam bingkai melengkung (rounded container) agar terlihat rapi dan modern. Di bagian bawah, disediakan dua tombol aksi utama, yaitu tombol "Batal" untuk membatasi proses dan kembali ke menu sebelumnya, serta tombol "Identifikasi" untuk melanjutkan ke tahap analisis penyakit. Tata letak yang bersih dan minimalis ini dirancang untuk memastikan fokus pengguna tetap tertuju pada akurasi visual objek sebelum dievaluasi oleh sistem.



Gambar 10 UI Halaman Hasil Deteksi

Hasil UI Deteksi yang menyajikan luaran informasi diagnosis penyakit daun apel secara komprehensif bagi pengguna. Struktur antarmuka ini menempatkan pratinjau citra daun yang diuji pada bagian atas, yang langsung diikuti oleh teks kesimpulan klasifikasi utama dan persentase nilai tingkat keyakinan (*confidence score*) dari model.



Gambar 11 UI Halaman Riwayat

Rancangan Halaman Riwayat Deteksi Rancangan ini merepresentasikan fitur manajemen data pengguna berbasis SQLite. Halaman ini menampilkan daftar (*list*) riwayat diagnosa yang pernah dilakukan sebelumnya, lengkap dengan *thumbnail* gambar, nama penyakit, dan tanggal pengambilan data, memudahkan pengguna untuk melakukan peninjauan kembali (*review*) tanpa harus memindai ulang.



Gambar 12 UI Halaman Detail Riwayat

Gambar mengilustrasikan daftar riwayat dari proses klasifikasi model MobileNetV2 yang telah dilakukan oleh pengguna. Informasi yang disajikan pada setiap kartu riwayat meliputi citra yang diuji, nama penyakit yang

terdeteksi, serta nilai tingkat keyakinan (*confidence score*) dari detail riwayat.

E. Sekema Pengujian Blackbox Testing

Tabel 5 Pengujian Blackbox Testing

No	Skenario Pengujian	Status
1	Melakukan upload foto daun apel dari galeri smartphone	Berhasil
2	Mengambil gambar daun apel secara langsung menggunakan kamera	Berhasil
3	Mengidentifikasi jenis penyakit pada daun apel menggunakan model yang telah di train	Berhasil
4	Menampilkan pratinjau (preview) gambar daun apel sesuai dengan foto yang telah diunggah atau di foto	Berhasil
5	Menampilkan data hasil identifikasi berupa nama penyakit	Berhasil
6	Menyimpan data hasil scan identifikasi secara otomatis ke dalam database lokal (SQLite)	Berhasil
7	Menampilkan daftar riwayat hasil scan terdahulu di halaman riwayat	Berhasil
8	Menampilkan detail riwayat yang di pilih	Berhasil
9	Menghapus data riwayat scan tertentu dari database pada halaman riwayat	Berhasil

Peneliti mengevaluasi tingkat keberhasilan fungsionalitas seluruh fitur aplikasi mobile menggunakan metode pengujian *Black Box Testing*. Sistem perangkat lunak ini membuktikan keandalan operasional yang sangat optimal dengan mencatatkan status "Berhasil" pada seluruh skenario uji fungsional tanpa mengalami kendala ataupun kesalahan program (*bug*). Pengguna sukses mengeksekusi integrasi fitur penangkapan citra, pemanggilan model TensorFlow Lite untuk proses diagnosis cerdas, hingga mekanisme penyimpanan otomatis ke dalam basis data lokal berbasis SQLite. Selain itu, antarmuka aplikasi juga secara responsif mampu menampilkan bagan pratinjau foto, perincian informasi penanganan infeksi tanaman, serta tata kelola menu riwayat deteksi secara akurat. Kompilasi data hasil pengukuran reliabilitas operasional sistem dari kesembilan butir instrumen pengujian terstruktur tersebut tersaji secara transparan pada file. Pengujian instrumen ini membuktikan bahwa arsitektur perangkat lunak gawai gantung tersebut sanggup meminimalkan potensi kegagalan sistem (*crash*) pada saat mengeksekusi berbagai instruksi berlapis secara simultan. Validasi fungsional yang menyeluruh ini sekaligus memberikan jaminan mutu

terhadap kesiapan aplikasi untuk dioperasikan secara masif oleh petani di area pertanian sesungguhnya.

F. Skema Pengujian Deteksi

Tabel 6 Skema Pengujian Deteksi

No	Skenario Pengujian	Variasi Pengujian	Status
1	Ground Truth	Apple Scab	Berhasil
		Black Rot	Berhasil
		Cedar Apple Rust	Berhasil
		Healthy	Berhasil
2	Pencahayaannya	Gelap	Berhasil
		Terang	Berhasil
3	Jarak Pengambilan Gambar	Dekat (10cm)	Berhasil
		Sedang (15cm)	Berhasil
		Jauh (20cm)	Berhasil

Peneliti memvalidasi performa stabilitas sistem inferensi seluler melalui skema pengujian deteksi sistem secara komprehensif. Perangkat lunak ini membuktikan ketangguhan komputasi yang sangat optimal dengan mencatatkan status "Berhasil" pada seluruh variasi skenario pengujian struktural tanpa hambatan teknis. Sistem kecerdasan buatan sukses mengeksekusi proses klasifikasi citra secara akurat pada empat kategori *Ground Truth* utama yang meliputi penyakit *Apple Scab*, *Black Rot*, *Cedar Apple Rust*, hingga kondisi daun *Healthy*. Selain itu, algoritma deteksi tetap mempertahankan konsistensi fungsionalitas yang sangat tinggi saat menghadapi fluktuasi intensitas pencahayaan lingkungan (gelap dan terang) serta variasi jarak pengambilan gambar dari rentang 10 cm, 15 cm, hingga 20 cm. Rekapitulasi data hasil pengukuran keandalan deteksi berdasarkan seluruh kombinasi skenario pengujian dinamis tersebut tersaji secara transparan pada file

IV. KESIMPULAN

Berdasarkan hasil eksperimen dan pengujian yang telah dilaksanakan, peneliti menyimpulkan bahwa implementasi arsitektur *Deep Learning* berbasis MobileNetV2 yang dikonversi ke dalam format TensorFlow Lite (.tflite) terbukti sangat efektif dan efisien untuk mendeteksi penyakit daun apel secara mandiri langsung di perangkat seluler petani. Pengujian model menunjukkan bahwa algoritma optimasi Adam memberikan performa klasifikasi paling superior dengan perolehan akurasi uji (*Test*

Accuracy) mencapai angka tertinggi sebesar 99,17% jika dibandingkan dengan optimizer RMSprop (99,39% pada validasi namun memiliki akurasi latih lebih rendah di kisaran 93%) dan SGD (97,83%). Selain itu, integrasi model kecerdasan buatan ke dalam aplikasi *mobile* berbasis framework Flutter dan basis data lokal SQLite sukses mencatatkan tingkat keberhasilan fungsionalitas 100% melalui *Black Box Testing*. Evaluasi skema deteksi sistem juga menegaskan bahwa aplikasi ini mampu mempertahankan konsistensi performa diagnosis yang sangat stabil dan adaptif terhadap berbagai variasi kondisi pencahayaan lapangan (gelap dan terang) serta fluktuasi jarak pengambilan gambar dari rentang 10 cm hingga 20 cm.

REFERENSI

- [1] T. P. Wardani, E. Yektiningsih, and M. Mubarakah, 'Faktor-Faktor yang Mempengaruhi Motivasi Petani dalam Mengembangkan Apel di Kecamatan Tukur Kabupaten Pasuruan', *Jurnal Ilmiah Manajemen Agribisnis*, vol. 12, no. 1, pp. 43–55, Jan. 2024, doi: 10.33005/jimaemagri.v12i1.25.
- [2] J. Shi *et al.*, 'Occurrence of *Neopestalotiopsis clavisporea* Causing Apple Leaf Spot in China', *Agronomy*, vol. 14, no. 8, p. 1658, Jul. 2024, doi: 10.3390/agronomy14081658.
- [3] S. I. Awan, R. Thapa, A. Svara, H. Feulner, N. Streb, and A. Khan, 'Evaluation of *Malus* Germplasm Identifies Genetic Sources of Powdery Mildew and Frogeye Leaf Spot Resistance for Apple Breeding', *Phytopathology*, vol. 113, no. 7, pp. 1289–1300, Jul. 2023, doi: 10.1094/PHYTO-11-22-0417-R.
- [4] 'Withdrawal: Next-generation methods for early disease detection in crops. A review', *Pest Manag. Sci.*, vol. 79, no. 10, pp. 4113–4113, Oct. 2023, doi: 10.1002/ps.7471.
- [5] E. Yilmaz, S. C. Bocekci, C. Safak, and K. Yildiz, 'Advancements in smart agriculture: A systematic literature review on state-of-the-art plant disease detection with computer vision', *IET Computer Vision*, vol. 19, no. 1, Jan. 2025, doi: 10.1049/cvi2.70004.
- [6] Dr. S. Mallick *et al.*, 'Agrovision: Deep Learning-Based Crop Disease Detection From Leaf Images', *Int. J. Environ. Sci.*, pp. 990–1005, Jul. 2025, doi: 10.64252/stgqg620.
- [7] V. Riyanto, S. Nurdianti, M. Marimin, M. Syukur, and S. N. Neyman, 'Deep Learning Approaches for Plant Disease Diagnosis Systems: A Review and Future Research Agendas', *Journal of Applied Agricultural Science and Technology*, vol. 9, no. 2, pp. 185–204, May 2025, doi: 10.55043/jaast.v9i2.308.
- [8] H. Cai *et al.*, 'Enable Deep Learning on Mobile Devices: Methods, Systems, and Applications', *ACM Transact. Des. Autom. Electron. Syst.*, vol. 27, no. 3, pp. 1–50, May 2022, doi: 10.1145/3486618.
- [9] H. Pu and K. Yi, 'A Comparative Analysis of EfficientNet and MobileNet Models' Performance on Limited Datasets: An Example of American Sign Language Alphabet Detection', *Highlights in Science, Engineering and Technology*, vol. 94, pp. 558–564, Apr. 2024, doi: 10.54097/yh5d3s04.
- [10] P. Chen, 'The MobileNet Family: Principles of Lightweight Design and Edge Deployment', *Applied and Computational Engineering*, vol. 235, no. 1, pp. 155–162, May 2026, doi: 10.54254/2755-2721/2026.GU33477.
- [11] M. G. Bhat and S. C. S., 'A Mobile-Based Deep Learning Approach for Mango Leaf Disease Detection Using TensorFlow Lite and Flutter Framework.', *INTERNATIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*, vol. 09, no. 08, pp. 1–9, Aug. 2025, doi: 10.55041/IJSREM52255.
- [12] A. Patel, R. R. N. S. Betgeri, S. Singhal, S. K. Singh, and M. Takodara, 'Utilizing TFLite and Machine Learning for the Early Detection of Mango Leaf Disease: An Automated Flutter Application', in *2024 5th International Conference for*

- Emerging Technology (INCET)*, IEEE, May 2024, pp. 1–6. doi: 10.1109/INCET61516.2024.10593509.
- [13] M. Belmir, W. Difallah, and A. Ghazli, 'A Reliable Apple Leaf Disease Identification Using a Deep Learning-Based MobileNetV2 to Safeguard Apple Fruit Safety', in *2024 4th International Conference on Embedded & Distributed Systems (EDiS)*, IEEE, Nov. 2024, pp. 279–284. doi: 10.1109/EDiS63605.2024.10783370.
 - [14] M. Jalal, U. Farooq, and A. Kaur, 'Explainable AI Meets MobileNetV2: A Multi-Branched Approach for Apple Leaf Disease Identification', *Applied Fruit Science*, vol. 67, no. 4, p. 271, Aug. 2025, doi: 10.1007/s10341-025-01478-5.
 - [15] V. Riyanto, S. Nurdianti, M. Marimin, M. Syukur, and S. N. Neyman, 'Deep Learning Approaches for Plant Disease Diagnosis Systems: A Review and Future Research Agendas', *Journal of Applied Agricultural Science and Technology*, vol. 9, no. 2, pp. 185–204, May 2025, doi: 10.55043/jaast.v9i2.308.
 - [16] J. Torres-Tello and S.-B. Ko, 'Optimizing a Multispectral-Images-Based DL Model, Through Feature Selection, Pruning and Quantization', in *2022 IEEE International Symposium on Circuits and Systems (ISCAS)*, IEEE, May 2022, pp. 1352–1356. doi: 10.1109/ISCAS48785.2022.9937940.
 - [17] B. M. Rashed and N. Popescu, 'Critical Analysis of the Current Medical Image-Based Processing Techniques for Automatic Disease Evaluation: Systematic Literature Review', *Sensors*, vol. 22, no. 18, p. 7065, Sep. 2022, doi: 10.3390/s22187065.
 - [18] C. B. Nwaneto and C. Yinka-Banjo, 'Harnessing deep learning algorithms for early plant disease detection: A comparative study and evaluation between SSD (Mobilenet_v2 and Mobilenet_v3) and CNN model', *Ife Journal of Science*, vol. 26, no. 3, pp. 555–568, Jan. 2025, doi: 10.4314/ijss.v26i3.1.
 - [19] M. G. Bhat and S. C. S., 'A Mobile-Based Deep Learning Approach for Mango Leaf Disease Detection Using TensorFlow Lite and Flutter Framework.', *INTERNATIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*, vol. 09, no. 08, pp. 1–9, Aug. 2025, doi: 10.55041/IJSREM52255.
 - [20] Q. Teng, Y. Tang, and G. Hu, 'RepHAR: Decoupling Networks With Accuracy-Speed Tradeoff for Sensor-Based Human Activity Recognition', *IEEE Trans. Instrum. Meas.*, vol. 72, pp. 1–11, 2023, doi: 10.1109/TIM.2023.3240198.