

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT DAUN PISANG MENGGUNAKAN CITRA DIGITAL

Sulton Ibnu Septiyan^{*,1)}, Nurlaily Vendyansyah²⁾, Deddy Rudhistiar³⁾

^{1,2,3)}Program Studi Teknik Informatika S1, Fakultas Teknik Industri, Institut Teknologi Nasional Malang
JL. Raya Karanglo KM. 2, Tasikmadu, Kec. Lowokwaru, Kota Malang, Jawa Timur 65153
Email: ¹ibnu.septian123@gmail.com, ²nurlaily.vendyansyah@lecturer.itn.ac.id, ³rudhistiar@lecturer.itn.ac.id

Abstract

Banana leaf diseases such as Cordana, Black Sigatoka, and Yellow Sigatoka can damage leaf tissues, disrupt photosynthesis, and reduce fruit productivity. The visual similarity of symptoms across these diseases also makes manual identification difficult for farmers, often leading to misdiagnosis, inappropriate pesticide application, and increased production costs. To address these problems, this study develops a banana leaf disease classification system using digital image processing based on the Convolutional Neural Network (CNN) method with the ResNet50V2 architecture. The dataset consists of five categories: Cordana, Black Sigatoka, Yellow Sigatoka, Healthy, and Non-Banana collected from PT Daun Kita Djoyo plantation in Malang. Image preprocessing includes resizing to 224×224 pixels, normalization, and augmentation using rotation, zoom, and flip. Model training and validation were carried out using TensorFlow and Keras on Google Colab, followed by implementation in a Flask-based web application. The ResNet50V2 model achieved a training accuracy of 96.08% and a validation accuracy of 96.01%, with loss values of 0.13 and 0.15. Testing on unseen data produced an average accuracy of 95.2%, supported by a confusion matrix indicating high precision for all classes. The developed web application enables users to upload banana leaf images and automatically obtain classification results with probability scores.

Keywords: *Banana leaf disease, Convolutional Neural Network, Digital image classification, Flask, ResNet50V2.*

Abstrak

Penyakit daun pisang seperti Cordana, Black Sigatoka, dan Yellow Sigatoka dapat merusak jaringan daun, menghambat proses fotosintesis, serta menurunkan produktivitas buah pisang. Kemiripan gejala visual antar penyakit juga membuat petani kesulitan mengidentifikasi kondisi daun secara akurat, sehingga berpotensi menimbulkan kesalahan diagnosis, penggunaan pestisida yang tidak tepat, dan peningkatan biaya produksi. Untuk mengatasi permasalahan tersebut, penelitian ini mengembangkan sistem klasifikasi penyakit daun pisang berbasis pengolahan citra digital menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur ResNet50V2. Dataset terdiri dari lima kategori—Cordana, Black Sigatoka, Yellow Sigatoka, Sehat, dan Non-Banana—yang dikumpulkan dari perkebunan PT Daun Kita Djoyo di Malang. Proses pre-processing meliputi penyesuaian ukuran citra menjadi 224×224 piksel, normalisasi, serta augmentasi menggunakan rotasi, zoom, dan flip. Pelatihan dan validasi model dilakukan dengan TensorFlow dan Keras di Google Colab, kemudian diimplementasikan pada aplikasi web berbasis Flask. Model menghasilkan akurasi pelatihan sebesar 96,08% dan akurasi validasi sebesar 96,01% dengan nilai loss 0,13 dan 0,15. Pengujian pada data baru memperoleh akurasi rata-rata 95,2% yang didukung oleh confusion matrix dengan tingkat presisi tinggi pada seluruh kelas. Sistem web yang dikembangkan memungkinkan pengguna mengunggah citra daun pisang dan memperoleh hasil klasifikasi secara otomatis beserta nilai probabilitas prediksinya.

Kata Kunci: Convolutional Neural Network, Flask, ResNet50V2, klasifikasi citra digital, penyakit daun pisang.

1. Pendahuluan

Tanaman pisang (*Musa paradisiaca L.*) adalah salah satu jenis tanaman yang tumbuh luas di hampir seluruh daerah Indonesia dan telah menyebar ke berbagai negara di dunia. Tanaman ini memiliki peluang besar untuk dibudidayakan secara intensif karena menjadi salah satu komoditas ekspor unggulan. [1]. Menurut data dari Badan Pusat Statistik (BPS) pada tahun 2022, jumlah total produksi pisang di Indonesia mencapai sekitar 9,2 juta ton, menjadikannya komoditas buah dengan tingkat produksi tertinggi di Indonesia. Meskipun demikian, produktivitas pisang sering mengalami penurunan



Jurnal Teknologi dan Sistem Tertanam is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).

akibat serangan penyakit daun seperti *Cordana*, *Pestalotiopsis*, dan *Sigatoka*, yang disebabkan oleh infeksi jamur maupun bakteri. Penyakit-penyakit tersebut dapat menurunkan hasil panen lebih dari 50% apabila tidak ditangani secara tepat [2].

Permasalahan utama di lapangan adalah terbatasnya kemampuan petani dalam mengenali jenis penyakit daun pisang secara akurat. Kesalahan diagnosis sering menyebabkan penggunaan pestisida yang tidak sesuai, meningkatkan biaya produksi, serta menimbulkan dampak negatif terhadap lingkungan. Kondisi ini diperparah oleh kesamaan gejala antara penyakit, serangan hama, dan kekurangan nutrisi [3]. Perkembangan teknologi kecerdasan buatan dan pembelajaran mendalam membuka banyak kesempatan dalam mendeteksi penyakit tanaman secara digital. Salah satu metode yang sering digunakan yaitu *Convolutional Neural Network* (CNN) karena kemampuannya dalam mengambil informasi visual seperti warna, tekstur, dan bentuk secara otomatis tanpa harus membuat fitur secara manual [4]. Pada penelitian ini, arsitektur ResNet50V2 dipilih karena memiliki mekanisme *residual learning* yang dapat mengatasi permasalahan *vanishing gradient* dan mampu memberikan tingkat akurasi yang lebih baik dari pada model CNN tradisional seperti VGG16 atau MobileNet.

Dataset penelitian diperoleh langsung dari perkebunan PT Daun Kita Djoyo di Pakis, Kabupaten Malang, Jawa Timur, yang mencakup lima kelas: *Cordana*, *Black Sigatoka*, *Yellow Sigatoka*, daun sehat, dan *non-banana*. Seluruh citra diambil melalui proses dokumentasi lapangan dan diberi label berdasarkan hasil observasi. Proses *pre-processing* meliputi *resize*, normalisasi, dan augmentasi citra. Model dilatih menggunakan *framework TensorFlow* dan *Keras* di platform *Google Colab*, kemudian diintegrasikan ke dalam aplikasi web berbasis *Flask* agar dapat digunakan oleh pengguna untuk mendeteksi penyakit.

Penelitian ini bertujuan untuk merancang dan mengimplementasikan arsitektur CNN ResNet50V2 dalam klasifikasi penyakit daun pisang berbasis citra digital serta mengembangkan sistem berbasis web yang mampu membedakan antara daun sehat dan yang terinfeksi. Sistem ini diharapkan bisa menjadi solusi teknologi yang membantu para petani dalam mendiagnosis penyakit secara lebih akurat, mengurangi kesalahan dalam penggunaan pestisida, serta mendukung peningkatan hasil produksi daun pisang di Indonesia.

Pada penelitian terdahulu [4], pemetaan kategori penyakit pada daun pisang telah dilakukan menggunakan metode *Convolutional Neural Network* (CNN) dengan berbagai jenis arsitektur, di antaranya *Flatten*, *AveragePooling2D*, dan *GlobalAveragePooling2D*. Eksperimen tersebut menghasilkan model *GlobalAveragePooling2D* dengan tingkat akurasi paling tinggi yaitu 93,62%, diikuti oleh *AveragePooling2D* sebesar 90,96%, dan *Flatten* yang mencapai akurasi 88,83%. Studi tersebut juga menyoroti peran data augmentasi dalam meningkatkan hasil prediksi model, serta peluang adopsi teknologi ke dalam aplikasi *mobile* agar proses deteksi penyakit oleh petani bisa berlangsung lebih cepat dan efisien.

Dalam penelitian yang berbeda [2], metode CNN diterapkan dengan memanfaatkan *transfer learning* dan teknik regularisasi *dropout* untuk mengklasifikasikan penyakit pada daun pisang. Model yang paling optimal dilatih dengan menggunakan proporsi data 70:20:10 selama 80 *epoch* dan mencapai akurasi 92%, presisi 92%, sensitivitas 91%, serta *F1-Score* 91%. Temuan ini menunjukkan bahwa CNN memiliki kemampuan klasifikasi yang sangat baik dan dapat mempercepat proses identifikasi penyakit pada tahap awal.

Dalam penelitian selanjutnya [5], perhatian utama tertuju pada klasifikasi kualitas pisang *Cavendish* dengan memanfaatkan arsitektur VGG16. Dataset yang digunakan terdiri dari 550 gambar, dengan proporsi 70% untuk pelatihan dan 30% untuk pengujian. Hasil terbaik dicapai pada *epoch* ke-50, dengan akurasi pelatihan mencapai 98,96% dan akurasi pengujian sebesar 83,53%. Penelitian ini mengindikasikan bahwa penerapan *deep learning* dapat digunakan untuk menilai kualitas pisang, yang memberikan dampak positif terhadap peningkatan nilai ekonomi produk.

Pada penelitian selanjutnya [6], CNN digunakan untuk mengklasifikasikan penyakit tanaman hias dengan lima kategori, yaitu bakteri, jamur, virus, hama, dan kondisi sehat. Sistem ini dikembangkan berbasis web menggunakan *Laravel* dan *FastAPI*, dengan akurasi pelatihan mencapai 89,67%. Sistem tersebut juga dilengkapi dengan fitur riwayat pengecekan dan rekomendasi perawatan tanaman.

Dalam penelitian [7], arsitektur ResNet50V2 diterapkan untuk mengklasifikasikan penyakit pada daun apel, yang terdiri dari empat kategori tiga jenis penyakit dan satu kategori sehat. Dataset yang digunakan mencakup 150 gambar yang diambil dari observasi lapangan serta 3.071 gambar yang diambil dari Kaggle. Model ini diuji dengan menggunakan metode *Waterfall* dan pengujian *black-box*, yang menghasilkan akurasi klasifikasi sebesar 99,01%. Hal ini menunjukkan bahwa ResNet50V2 sangat efektif dalam mendeteksi penyakit tanaman berdasarkan gambar digital.

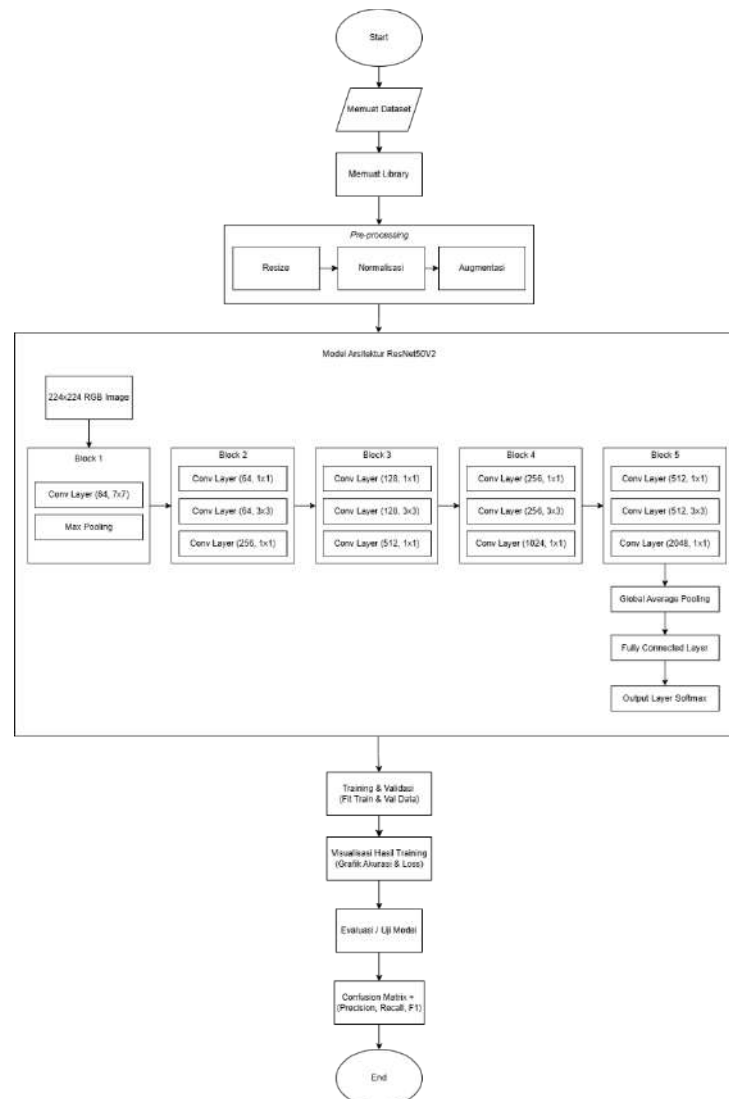
Meskipun penelitian sebelumnya telah membuktikan efektivitas CNN dalam klasifikasi penyakit tanaman atau buah, sebagian besar masih menggunakan dataset dari internet atau repositori publik sehingga kurang merepresentasikan kondisi lapangan yang sesungguhnya. Selain itu, penggunaan arsitektur ResNet50V2 pada kasus penyakit daun pisang masih belum ada, model ini memiliki kelebihan dalam stabilitas pelatihan dan akurasi. Penelitian terdahulu juga umumnya tidak mengintegrasikan model ke dalam sistem berbasis web yang dapat digunakan langsung oleh petani. Berdasarkan gap tersebut, penelitian ini memberikan kontribusi baru melalui penggunaan dataset lapangan asli, penerapan arsitektur ResNet50V2, serta pengembangan aplikasi web yang memungkinkan deteksi penyakit dilakukan secara cepat oleh pengguna.

Keterbaruan dari penelitian ini terletak pada penggunaan dataset citra daun pisang yang dikumpulkan secara langsung dari perkebunan PT Daun Kita Djoyo sehingga kondisi citra merepresentasikan situasi lapangan secara langsung, berbeda dari penelitian sebelumnya yang sebagian besar menggunakan dataset dari internet atau repositori publik. Selain itu, penelitian ini memanfaatkan arsitektur ResNet50V2 dengan *pre-processing* berupa *resize 224×224*

piksel, normalisasi, dan augmentasi yang disesuaikan dengan karakteristik citra daun pisang asli. Penelitian sebelumnya banyak berfokus pada arsitektur CNN dasar, VGG16, atau *pooling layer* tanpa menguji performa pada penyakit daun pisang. Keterbaruan lain terdapat pada integrasi model ke dalam aplikasi web berbasis Flask yang memungkinkan proses klasifikasi dilakukan secara otomatis oleh pengguna di lapangan.

2. Metode

Alur penelitian ini terlihat pada Gambar 1, yang menunjukkan langkah-langkah utama dalam pembuatan model klasifikasi penyakit daun pisang.



Gambar 1. Tahapan Utama

Tahapan tersebut meliputi proses pengumpulan dataset citra daun pisang, tahap *pre-processing* (*resize*, normalisasi, dan augmentasi) untuk menyiapkan data, klasifikasi menggunakan metode CNN arsitektur ResNet50V2, serta pengujian performa model menggunakan *confusion matrix*. Setiap tahap saling berhubungan secara berurutan untuk menghasilkan model yang optimal dan dapat diimplementasikan dalam sistem deteksi penyakit daun pisang berbasis web.


2.1 Dataset dan Sumber Data

Dataset diperoleh melalui dokumentasi langsung di perkebunan PT Daun Kita Djoyo, Pakis, Kabupaten Malang, Jawa Timur. Objek penelitian adalah daun pisang varietas pisang batu yang mencakup lima kelas: *Cordana*, *Black Sigatoka*, *Yellow Sigatoka*, *Healthy*, dan *Non-Banana*. Setiap citra diambil menggunakan kamera ponsel dengan pencahayaan alami dan sudut pandang bervariasi untuk meningkatkan keragaman dataset. Citra diberi label sesuai hasil observasi lapangan untuk memastikan kesesuaian antara kondisi citra dan penyakit aktual di lapangan. Total dataset yang digunakan berjumlah 3.793 citra, dengan distribusi sebagai berikut:

Tabel 1. Jumlah Dataset Citra Daun Pisang

Kelas	Jumlah Citra
<i>Healthy</i>	700
<i>Cordana</i>	700
<i>Black Sigatoka</i>	700
<i>Yellow Sigatoka</i>	700
<i>Non-Banana</i>	993
Total	3.793


Dataset kemudian dibagi ke dalam data latih, validasi, dan uji menggunakan tiga skema rasio, yaitu 70:30, 80:20, dan 90:10. Pembagian dilakukan secara proporsional pada setiap kelas untuk menjaga keseimbangan data. Kelas *Non-Banana* memiliki jumlah citra lebih banyak karena berfungsi memperkuat kemampuan model dalam mengenali citra yang tidak termasuk kategori daun pisang, sehingga dapat mengurangi kesalahan klasifikasi.



Gambar 2. (a) *Healthy*, (b) *Cordana*, (b) *Black Sigatoka*, (c) *Yellow Sigatoka*

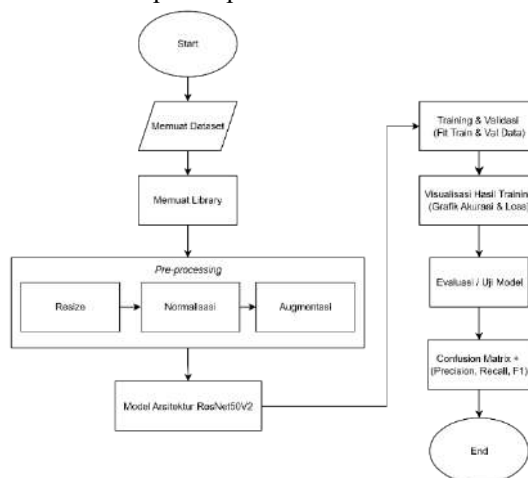
2.2 Model CNN

Convolutional Neural Network (CNN) adalah salah satu algoritma dalam bidang *Deep Learning* yang umum digunakan, khususnya dalam pengolahan citra digital. CNN dikembangkan dari arsitektur *Multi-Layer Perceptron (MLP)*, namun memiliki keunggulan dalam menangani data visual dua dimensi karena kemampuannya mengekstraksi fitur spasial secara otomatis. Algoritma ini beroperasi dengan mengekstraksi fitur penting dari citra melalui proses konvolusi dan *pooling*, lalu melakukan klasifikasi menggunakan pendekatan *supervised learning*, yaitu pembelajaran yang memanfaatkan data pelatihan dan data pengujian [8]. Contoh arsitektur CNN untuk klasifikasi gambar bisa dilihat pada Gambar 3.



Gambar 3. Model *Convolutional Neural Network* [8]

Alur implementasi CNN pada penelitian ini mencakup beberapa tahap, yaitu persiapan data, penyusunan *library* yang diperlukan, proses *pre-processing* data, perancangan arsitektur model, serta tahap pelatihan, validasi, dan evaluasi. Secara singkat, rangkaian tahapan tersebut ditampilkan pada Gambar 4.



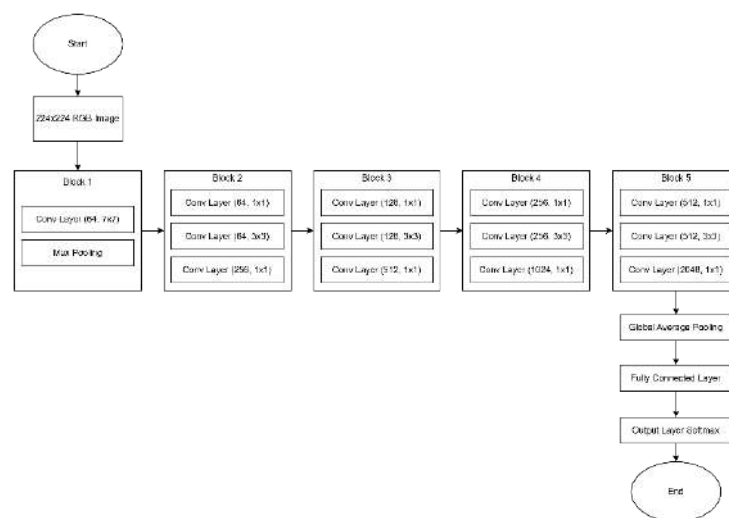
Gambar 4. Tahapan Flowchart Metode CNN

Tahap awal dimulai dengan pemuatan dataset berupa citra daun pisang yang dikategorikan ke dalam lima kelas,

yaitu *Cordana*, *Healthy*, *Black Sigatoka*, *Yellow Sigatoka*, dan *Non-Banana*. Dataset tersebut diatur dalam folder terpisah untuk data pelatihan, validasi, dan pengujian agar proses pembelajaran, validasi, serta evaluasi model dapat dilakukan secara mandiri. Setelah itu, dilakukan pemanggilan sejumlah *library* Python seperti *TensorFlow*, *Keras*, *NumPy*, *OpenCV*, dan *Matplotlib*, yang berfungsi untuk membangun arsitektur model, mengolah citra, serta menampilkan hasil visualisasi.

2.3 Arsitektur ResNet50V2

ResNet50V2 merupakan model jaringan saraf tiruan berbasis konvolusi (CNN) yang dikembangkan sebagai penyempurnaan dari ResNet50. Model ResNet50 pertama kali dikemukakan oleh tim peneliti dari *Microsoft Research* pada tahun 2015 melalui penelitian berjudul “*Deep Residual Learning for Image Recognition*”, yang berhasil memenangkan kompetisi *ImageNet Large Scale Visual Recognition Challenge (ILSVRC)*. Model ini termasuk dalam keluarga arsitektur ResNet dengan 50 lapisan dan menempati posisi menengah di antara varian lain. Dibandingkan dengan arsitektur ResNet yang lain seperti ResNet101 atau ResNet152, ResNet50 memiliki keunggulan karena lebih ringan secara komputasi namun tetap lebih kompleks dibandingkan ResNet18 dan ResNet34. Keseimbangan antara kedalaman jaringan dan efisiensi komputasi inilah yang menjadi alasan pemilihan ResNet50V2 dalam penelitian ini. ResNet50V2 menerapkan konsep *residual block* dengan mekanisme *skip connection* yang membantu aliran gradien menjadi lebih efisien selama proses pelatihan. Pendekatan ini mampu mengurangi terjadinya masalah *vanishing gradient* dan meningkatkan performa klasifikasi, terutama pada citra dengan resolusi tinggi [9].



Gambar 5. Flowchart Arsitektur ResNet50V2

2.4 Pre-processing Citra

Proses *pre-processing* citra diperlukan untuk menyiapkan gambar agar sesuai dengan kebutuhan model yang dikembangkan. Tahap ini membantu model bekerja lebih efektif dan efisien dalam mengekstraksi fitur serta melakukan klasifikasi atau deteksi terhadap citra yang diproses [10]. Tahap awal *pre-processing* dilakukan dengan menyesuaikan ukuran citra menjadi 224 x 224 piksel agar sesuai dengan kebutuhan arsitektur model ResNet50V2. Selanjutnya, untuk ukuran *batch* ditentukan sebesar 32 untuk memaksimalkan efisiensi penggunaan memori selama proses pelatihan. Pemilihan pada ukuran *batch* tersebut didasarkan pada pertimbangan keseimbangan antara kecepatan pelatihan, efisiensi memori, dan kemampuan model untuk mencapai konvergensi yang optimal [7]. Selanjutnya, normalisasi data citra dilakukan dengan menyesuaikan nilai yang digunakan untuk perbandingan data sebelum data tambahan dimasukkan. Misalnya, gambar berwarna atau dalam format RGB (*Red*, *Green*, *Blue*) memiliki rentang nilai 0-255, yang berdampak pada data saat melakukan pelatihan. Untuk mengatasi masalah tersebut, nilai dapat diskalakan dengan faktor 1/255, sehingga menghasilkan rentang nilai 0-1 [9].

Augmentasi dilakukan dengan beberapa teknik seperti rotasi, *flipping* horizontal, *zoom*, dan penyesuaian kecerahan, sehingga model dapat mengenali daun dalam berbagai kondisi dan pencahayaan. Augmentasi bertujuan untuk meningkatkan variasi dalam dataset tanpa harus mengumpulkan data baru [7]. Selanjutnya, dataset dipisahkan menjadi data pelatihan dan data validasi dengan berbagai rasio untuk mendukung proses *training* serta evaluasi model.

2.5 Konfigurasi Model dan Hiperparameter

Proses hiperparameter berperan penting dalam mengoptimalkan serta meningkatkan kinerja model CNN. Beberapa hiperparameter seperti *epoch*, ukuran *batch*, *learning rate*, dan jenis *optimizer* umumnya disesuaikan untuk memperoleh performa CNN yang lebih optimal. Pada penelitian ini, peneliti melakukan penyetelan hiperparameter pada *epoch*, *batch size*, *learning rate*, dan *optimizer* selama proses pelatihan model. Kinerja model kemudian dievaluasi menggunakan *confusion matrix* untuk memperoleh nilai akurasi, *precision*, *recall*, dan *f1-score* [11].

Untuk memastikan proses pelatihan berjalan optimal, diperlukan serangkaian pengaturan hiperparameter yang mengendalikan cara model mempelajari pola dari data citra. Hiperparameter ini mencakup konfigurasi *input*, arsitektur model, proses optimasi, serta augmentasi yang digunakan. Rincian lengkap hiperparameter yang diterapkan pada penelitian ini pada Tabel 2 berikut.

Tabel 2. Hiperparameter Model ResNet50V2

Komponen	Hiperparameter	Nilai
<i>Input</i>	Ukuran citra	224 × 224 piksel
<i>Batch</i>	<i>Batch size</i>	32
<i>Epoch</i>	Jumlah <i>epoch</i>	20, 30, 40, 50
<i>Optimizer</i>	Jenis <i>optimizer</i>	Adam
	<i>Learning rate</i>	0.0001
Augmentasi	Rotasi	20°
	Zoom	1.2
	Flip horizontal	Ya
Arsitektur Model	<i>Base model</i>	ResNet50V2
	<i>Global Average Pooling</i>	Ya
	<i>Dropout</i>	0.4
	<i>Dense layer</i>	128 neuron (ReLU)
	<i>Output layer</i>	5 neuron (Softmax)

Dengan konfigurasi hiperparameter tersebut, model ResNet50V2 dapat dilatih secara konsisten pada seluruh skema pembagian data. Pengaturan ini juga memastikan bahwa proses pelatihan berjalan stabil serta menghasilkan performa klasifikasi yang optimal pada tahap pengujian berikutnya.

2.6 Rancangan Sistem

Perancangan sistem ini bertujuan untuk mengintegrasikan model *Convolutional Neural Network* (CNN) arsitektur ResNet50V2 yang sudah melalui proses pelatihan ke dalam platform aplikasi web berbasis Flask. Sistem tersebut dirancang agar pengguna dapat melakukan klasifikasi penyakit pada daun pisang dengan cepat dan mudah melalui antarmuka web. Secara umum, alur kerja pada sistem dapat dilihat pada Gambar 6 berikut.



Gambar 6. Proses Klasifikasi Penyakit Daun Pisang

Pada gambar tersebut menunjukkan alur kerja sistem yang dimulai dari pengguna mengunggah citra daun pisang berformat JPG atau PNG ke dalam sistem. Setelah citra diterima, sistem akan melakukan tahap *pre-processing* berupa *resize* dan normalisasi citra agar sesuai dengan format input model. Selanjutnya, sistem memuat model CNN arsitektur ResNet50V2 hasil pelatihan untuk melakukan proses prediksi terhadap citra tersebut.

Hasil prediksi yang diperoleh berupa label kelas penyakit seperti *Cordana*, *Black Sigatoka*, *Yellow Sigatoka*, Sehat, atau *Non-Banana*, beserta nilai akurasi. Hasil klasifikasi kemudian ditampilkan pada antarmuka web sehingga pengguna dapat mengetahui jenis penyakit daun pisang secara langsung. Dengan rancangan sistem ini, pengguna tidak perlu memahami aspek teknis pemrograman atau pelatihan model, karena seluruh proses klasifikasi dilakukan secara otomatis melalui sistem berbasis web yang responsif dan mudah digunakan.

2.7 Confusion matrix

Confusion matrix merupakan salah satu metode evaluasi yang digunakan untuk mengukur sejauh mana tingkat keakuratan dan performa suatu model klasifikasi. Melalui pendekatan ini, hasil prediksi model dibandingkan dengan label aktual guna mengidentifikasi sejauh mana sistem mampu mengenali kategori secara benar. Metode ini terdiri atas empat komponen utama yang menjadi dasar perhitungannya, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) [2].

Untuk mengevaluasi hasil pelatihan, digunakan *confusion matrix* yang menggambarkan perbandingan antara prediksi model dan label sebenarnya. Setiap nilai tersebut dimanfaatkan untuk menghitung sejumlah metrik evaluasi kinerja model, antara lain *accuracy*, *precision*, *recall*, serta *F1-score*, yang dirumuskan sebagai berikut :

1. Akurasi (*Accuracy*)

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

2. Presisi (*Precision*)

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

3. Sensitivitas (*Recall*)

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

4. F1-Score

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

Keterangan:

TP (*True Positive*): jumlah data dengan kelas positif yang berhasil diprediksi dengan benar.

TN (*True Negative*): jumlah data dengan kelas negatif yang berhasil diprediksi dengan benar.

FP (*False Positive*): jumlah data berkategori negatif yang keliru diklasifikasikan sebagai positif.

FN (*False Negative*): jumlah data berkategori positif yang keliru diklasifikasikan sebagai negatif.

2.8 BlackBox Testing

Black box testing merupakan metode uji coba perangkat lunak dengan menitikberatkan pada aspek fungsional sistem dengan menilai hubungan antara *input* dan *output* tanpa memeriksa struktur internal atau kode sumber program. Teknik ini dilakukan berdasarkan spesifikasi kebutuhan yang telah ditetapkan sebelumnya dan tidak memerlukan akses langsung terhadap kode aplikasi, sehingga pengujian dilakukan sepenuhnya dari sudut pandang pengguna. Pendekatan *black box* testing memiliki peran penting dalam memastikan seluruh fungsi sistem telah beroperasi sesuai dengan yang diharapkan. Keunggulan utama metode ini adalah tidak menuntut penguji untuk memiliki kemampuan pemrograman atau pemahaman teknis terkait implementasi kode, sehingga dapat diterapkan oleh siapa pun yang memahami kebutuhan dan alur bisnis sistem yang diuji [9]. Perancangan kasus uji dilakukan dengan menganalisis berbagai kondisi input yang mencakup data valid dan tidak valid, yang dapat berupa nilai numerik, rentang angka, maupun variabel logika (*Boolean*). Melalui pendekatan ini, setiap kelompok *input* diuji untuk memastikan bahwa sistem bisa menghasilkan *output* yang sesuai dengan kebutuhan dan ekspektasi pengguna [10].

3. Hasil dan Pembahasan

3.1 Skema Pengujian

Untuk mendapatkan hasil terbaik, dilakukan beberapa uji coba dengan variasi parameter pelatihan agar mengetahui dampaknya terhadap kemampuan model ResNet50V2. Tujuan dari uji coba ini adalah menemukan kombinasi dari rasio pembagian data, jumlah *epoch*, serta parameter pelatihan lainnya yang mampu memberikan tingkat akurasi tertinggi. Skema pengujian bisa dilihat pada Tabel 3. berikut.

Tabel 3. Skema Pengujian Model ResNet50V2

Skenario	Keterangan
Pembagian Data	70% latih , 15% validasi , 15% uji 80% latih , 10% validasi , 10% uji 90% latih , 5% validasi , 5% uji
Kelas	<i>Cordana, Healthy, Black Sigatoka, Yellow Sigatoka, dan Non-banana</i>
Ukuran Data	224 x 224 <i>pixel</i>
<i>Batch Size</i>	32
<i>Epoch</i>	20,30,40,50

Setelah rancangan skema pengujian ditentukan sebagaimana Tabel 1, proses selanjutnya adalah melakukan pelatihan dan pengujian model untuk memperoleh konfigurasi terbaik.

3.2 Pelatihan dan Pengujian Model


Setelah rancangan skema pengujian ditetapkan sebagaimana ditunjukkan pada Tabel 1, tahap selanjutnya adalah melakukan proses pelatihan (*training*) dan pengujian (*testing*) model CNN arsitektur ResNet50V2 dengan berbagai variasi rasio pembagian data dan jumlah *epoch*. Tujuan dari tahap ini adalah menelaah pengaruh perbedaan rasio data serta total *epoch* pelatihan terhadap hasil akurasi dan *loss* pada data pelatihan serta validasi.

Tabel 4. Hasil Percobaan Pelatihan Model ResNet50V2

Percobaan ke	Pembagian	<i>Epochs</i>	Data Latih		Data Validasi	
			Akurasi	<i>Loss</i>	Akurasi	<i>Loss</i>
1	70:30	20	0.94	0.16	0.92	0.19
2	70:30	30	0.94	0.14	0.93	0.17
3	70:30	40	0.96	0.13	0.96	0.15

4	70:30	50	0.96	0.10	0.92	0.16
5	80:20	20	0.93	0.14	0.92	0.17
6	80:20	30	0.94	0.13	0.94	0.15
7	80:20	40	0.94	0.12	0.92	0.17
8	80:20	50	0.95	0.11	0.94	0.13
9	90:10	20	0.93	0.16	0.88	0.23
10	90:10	30	0.95	0.12	0.88	0.23
11	90:10	40	0.95	0.11	0.91	0.21
12	90:10	50	0.96	0.10	0.92	0.21

Dari hasil pelatihan diperoleh bahwa rasio 70:30 dengan jumlah 40 *epoch* menghasilkan performa terbaik, dengan akurasi pelatihan dan validasi masing-masing sebesar 0.96. Nilai *loss* yang dihasilkan juga tergolong rendah, yaitu 0.13 pada data pelatihan dan 0.15 pada data validasi. Temuan ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru tanpa mengalami *overfitting*.

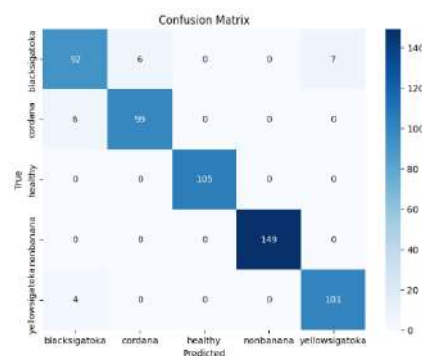


Gambar 7. Grafik Akurasi dan Loss

Gambar 7 menampilkan grafik hasil pelatihan model CNN dengan arsitektur ResNet50V2 pada rasio data 70:30 dan jumlah *epoch* sebanyak 40. Grafik di sisi kiri menunjukkan peningkatan yang cukup signifikan pada nilai akurasi pelatihan (*Train Accuracy*) serta akurasi validasi (*Validation Accuracy*) di awal proses pelatihan, kemudian menjadi stabil setelah melewati *epoch* ke-20 dan hasilnya di sekitar nilai 0.96. Kestabilan kedua kurva tersebut mengindikasikan bahwa model berhasil mempelajari pola pada data pelatihan secara optimal tanpa mengalami gejala *overfitting*.

Sementara itu, grafik di sisi kanan menampilkan penurunan dari nilai *loss* pada data pelatihan (*Train Loss*) dan data validasi (*Validation Loss*) yang terjadi secara konsisten hingga mencapai nilai mendekati 0.1 pada akhir *epoch*. Kecenderungan penurunan yang sejalan antara kedua jenis data tersebut menunjukkan bahwa proses optimasi model berlangsung secara efektif dan stabil.

Selanjutnya, dilakukan pengujian performa model dengan menggunakan *confusion matrix* untuk menilai tingkat ketepatan klasifikasi setiap kelas daun pisang. Gambar 8 menunjukkan bahwa model dapat mengklasifikasikan citra daun pisang dengan sangat baik, ditunjukkan oleh dominasi nilai prediksi pada diagonal utama yang menunjukkan kesesuaian antara kelas prediksi dan kelas aktual.



Gambar 8. Confusion Matrix

Berdasarkan hasil *confusion matrix* tersebut, kelas *Healthy* dan *Non-Banana* berhasil diklasifikasikan secara sempurna dengan tingkat ketepatan 100%, masing-masing sebanyak 105 dan 149 citra. Sementara itu, kelas *Black Sigatoka* dan *Yellow Sigatoka* masih menunjukkan sedikit kesalahan prediksi, kemungkinan disebabkan oleh kemiripan warna dan tekstur antar kelas. Secara keseluruhan, *confusion matrix* ini menunjukkan bahwa model ResNet50V2 memiliki performa yang sangat baik dengan tingkat kesalahan klasifikasi yang rendah serta kemampuan generalisasi yang tinggi.

Untuk melengkapi analisis evaluasi model, dilakukan pula perhitungan metrik *precision*, *recall*, dan *F1-score* yang ditampilkan pada Tabel 5 berikut. Tabel ini menggambarkan performa model pada setiap kelas secara lebih rinci berdasarkan hasil pengujian sebanyak 569 citra.

Tabel 5. Hasil Perhitungan *Precision*, *Recall*, dan *F1-Score*

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<i>Black Sigatoka</i>	0.85	0.90	0.87	105
<i>Cordana</i>	0.95	0.91	0.93	105
<i>Healthy</i>	1.00	1.00	1.00	105
<i>Non-Banana</i>	1.00	1.00	1.00	149
<i>Yellow Sigatoka</i>	0.94	0.93	0.94	105
<i>Accuracy</i>	–	–	0.95	569
<i>Macro Avg</i>	0.95	0.95	0.95	569
<i>Weighted Avg</i>	0.95	0.95	0.95	569

Hasil ini menunjukkan bahwa model ResNet50V2 mampu melakukan klasifikasi penyakit daun pisang dengan sangat baik, dibuktikan oleh nilai *F1-score* yang tinggi pada seluruh kelas (≥ 0.87) dan akurasi keseluruhan mencapai 0.95. Dengan demikian, model memiliki tingkat konsistensi dan ketepatan prediksi yang kuat pada data uji.

3.3 Analisis Performa Model Berdasarkan Setiap Kelas

Setelah memperoleh hasil evaluasi performa melalui tabel *precision*, *recall*, dan *F1-score* pada Tabel 5, diperlukan analisis lebih mendalam untuk mengetahui bagaimana model bekerja pada setiap kelas citra daun pisang. Analisis per kelas ini bertujuan untuk memahami faktor-faktor yang memengaruhi keberhasilan maupun kesalahan prediksi, sehingga dapat memberikan gambaran yang lebih komprehensif mengenai kemampuan model ResNet50V2 dalam membedakan masing-masing kategori penyakit. Pembahasan per kelas dijelaskan sebagai berikut.

1. Kelas *Healthy*

Model berhasil mengklasifikasikan kelas *Healthy* dengan nilai *precision*, *recall*, dan *F1-score* sebesar 1.00, menunjukkan tidak ada kesalahan prediksi. Keberhasilan ini disebabkan oleh ciri visual daun sehat yang relatif konsisten, seperti warna hijau merata tanpa bercak sehingga fitur yang diekstraksi model lebih mudah dibedakan dari kelas lainnya.

2. Kelas *Non-Banana*

Kelas *Non-Banana* juga mencapai skor sempurna pada seluruh metrik. Hal ini disebabkan oleh perbedaan tekstur, pola, dan warna yang cukup kontras dibandingkan daun pisang asli. Jumlah data yang lebih banyak pada kelas ini (993 citra) turut membantu model belajar variasi yang lebih luas.

3. Kelas *Cordana*

Kelas *Cordana* memiliki *precision* 0.95 dan *recall* 0.91. Meskipun performanya tinggi, beberapa citra *Cordana* terprediksi sebagai kelas lain. Hal ini dapat terjadi karena pola bercak *Cordana* pada beberapa sampel memiliki kemiripan visual dengan gejala awal *Black Sigatoka* atau pada *Yellow Sigatoka*. Perbedaan intensitas warna bercak yang tipis menjadi salah satu penyebab model sesekali keliru.

4. Kelas *Black Sigatoka*

Pada kelas ini, nilai *precision* sebesar 0.85 dan *recall* 0.90 menunjukkan adanya beberapa kesalahan prediksi. *Black Sigatoka* memiliki tekstur bercak kehitaman yang kadang menyerupai *shadow* atau *noise* pada citra dengan pencahayaan gelap. Selain itu, beberapa daun *Black Sigatoka* yang tingkat infeksiya masih ringan memiliki pola yang mirip *Cordana* sehingga menyebabkan kesalahan kelas.

5. Kelas *Yellow Sigatoka*

Nilai *precision* 0.94 dan *recall* 0.93 menunjukkan performa sangat baik, meskipun tidak sempurna. *Yellow Sigatoka* memiliki ciri bercak kuning dengan tepi kecoklatan yang kadang menyerupai bercak *Cordana* dengan intensitas tertentu. Variasi warna kuning yang dipengaruhi cahaya juga dapat membuat model mengalami salah kelas.

Berdasarkan analisis mendalam pada setiap kelas, terlihat bahwa model ResNet50V2 mampu mengenali pola visual dengan sangat baik pada kelas *Healthy* dan *Non-Banana*, sementara tingkat kesalahan pada kelas *Black Sigatoka* dan *Yellow Sigatoka* umumnya disebabkan oleh kemiripan tekstur dan warna antar penyakit. Secara keseluruhan, evaluasi per kelas menunjukkan bahwa model memiliki kemampuan generalisasi yang kuat dan konsisten dalam mengklasifikasikan penyakit daun pisang.


3.4 Implementasi Sistem Berbasis Web

Implementasi sistem berbasis web dilakukan untuk memudahkan pengguna dalam melakukan klasifikasi penyakit daun pisang secara cepat dan praktis. Sistem ini dibangun menggunakan *framework* Flask dengan integrasi model CNN ResNet50V2 yang telah dilatih sebelumnya. Dengan sistem ini, pengguna dapat mengunggah gambar daun pisang dan secara langsung memperoleh hasil klasifikasi sesuai dengan prediksi yang dihasilkan oleh model.




Gambar 9. Halaman *Dashboard User*

Gambar 9 menampilkan halaman *dashboard user* yang berfungsi sebagai tampilan utama sistem setelah pengguna masuk. Pada halaman ini, pengguna dapat mengakses fitur utama sistem seperti menu klasifikasi dan riwayat hasil klasifikasi.




Gambar 10. Halaman Klasifikasi Unggah Citra



Gambar 11. Halaman Hasil Klasifikasi *User*

Gambar diatas menunjukkan halaman klasifikasi user yang merupakan inti dari sistem. Pada halaman ini pengguna dapat mengunggah citra daun pisang melalui tombol *upload image*, kemudian sistem akan menampilkan hasil prediksi berupa jenis penyakit daun (misalnya *Black Sigatoka*, *Cordana*, *Healthy*, atau *Non-Banana*) beserta nilai akurasi.



Gambar 12. Halaman Riwayat Klasifikasi

Gambar 12 menampilkan tampilan halaman Riwayat Klasifikasi pada sistem yang berfungsi untuk menampilkan seluruh hasil klasifikasi citra daun pisang yang telah dilakukan oleh pengguna sebelumnya. Setiap hasil klasifikasi yang ditampilkan pada halaman ini mencakup informasi seperti nama file gambar, jenis penyakit hasil prediksi (misalnya *Cordana*, *Black Sigatoka*, *Yellow Sigatoka*, *Healthy*, atau *Non-Banana*), serta waktu klasifikasi. Fitur ini memudahkan pengguna untuk meninjau kembali hasil prediksi tanpa perlu melakukan klasifikasi ulang. Selain itu, pengguna juga dapat menghapus data riwayat tertentu melalui tombol hapus yang tersedia agar pengelolaan data lebih efisien.

Hasil implementasi menunjukkan bahwa sistem mampu melakukan klasifikasi citra daun pisang secara otomatis dan menampilkan hasil dengan akurasi tinggi sesuai performa model yang diperoleh pada tahap pelatihan. Integrasi antara model CNN dan antarmuka berbasis Flask menjadikan sistem ini responsif dan mudah dioperasikan oleh pengguna tanpa memerlukan pengetahuan teknis mendalam.

3.5 Pengujian BlackBox

Setelah tahap implementasi website, dilakukan uji perangkat lunak dengan menggunakan pendekatan *Black Box*

untuk memastikan seluruh fungsi sistem berjalan sesuai kebutuhan pengguna. Pengujian ini dilakukan oleh 5 orang responden, yaitu para petani dari kawasan perkebunan PT Daun Kita Djoyo yang pengguna utama sistem. Setiap responden diminta mencoba seluruh fitur sistem, seperti proses *login*, registrasi, unggah citra, dan melihat riwayat klasifikasi untuk memastikan bahwa sistem dapat digunakan dengan baik di lapangan.

Tabel 6. Pengujian Sistem Menggunakan Metode Black Box

No	Skenario Pengujian	Input	Output yang Diharapkan	Hasil Pengujian
1	<i>Login</i> menggunakan data valid	Data <i>email</i> dan <i>password</i> benar	Sistem menampilkan dashboard sesuai <i>role user/admin</i>	Sesuai
2	<i>Login</i> menggunakan data tidak valid	Data <i>email</i> atau <i>password</i> salah	Sistem menampilkan pesan “ <i>Login gagal</i> ”	Sesuai
3	Registrasi akun baru	Nama, <i>email</i> , <i>password</i> valid	Akun berhasil dibuat dan diarahkan ke halaman <i>login</i>	Sesuai
4	<i>Upload</i> citra daun pisang	<i>File</i> gambar format .jpg/.png	Sistem menampilkan hasil klasifikasi (<i>Cordana, Black Sigatoka, Yellow Sigatoka, Healthy</i> , atau Bukan Daun Pisang)	Sesuai
5	<i>Upload</i> file non-gambar	<i>File</i> PDF/TXT	Sistem menolak unggahan dan menampilkan pesan <i>error</i>	Sesuai
6	Lihat Riwayat Klasifikasi	Klik menu “Riwayat Klasifikasi”	Sistem menampilkan daftar hasil klasifikasi sebelumnya	Sesuai
7	Hapus Data Riwayat	Klik tombol hapus pada data klasifikasi	Data berhasil dihapus dari <i>database</i>	Sesuai
8	Edit Profil Pengguna	Ubah nama/ <i>email</i> / <i>password</i>	Data profil berhasil diperbarui di <i>database</i>	Sesuai
9	Lihat Data Klasifikasi (Admin)	Klik menu “Hasil Klasifikasi”	Sistem menampilkan seluruh hasil klasifikasi pengguna	Sesuai
10	Hapus Data Pengguna (Admin)	Klik tombol hapus pada data user	Data pengguna berhasil dihapus dari sistem	Sesuai

Sistem selanjutnya diuji pada empat *browser desktop* utama untuk memastikan tampilan dan seluruh fungsi tetap berjalan stabil pada lingkungan yang berbeda. Hasil pengujian ditampilkan pada Tabel 7 berikut.

Tabel 7. Pengujian Sistem pada *Browser Desktop*

No	Jenis Pengujian	Google Chrome	Mozilla Firefox	Microsoft Edge	Safari	Detail Pengujian
1	Tampilan Halaman	✓	✓	✓	✓	Memastikan halaman utama, <i>login</i> , <i>dashboard</i> , dan halaman klasifikasi tampil sempurna tanpa pergeseran elemen.
2	Responsif Halaman pada Berbagai Layar	✓	✓	✓	✓	Memastikan seluruh halaman (<i>user & admin</i>) menyesuaikan ukuran layar <i>desktop</i> , <i>tablet</i> , dan <i>mobile</i> dengan baik.
3	Kompatibilitas JavaScript	✓	✓	✓	✓	Menguji apakah seluruh fungsi berbasis <i>JavaScript</i> (tombol navigasi, <i>alert</i> , <i>upload</i> gambar) berjalan tanpa <i>error</i> .
4	Proses Login Pengguna	✓	✓	✓	✓	Menguji proses <i>login</i> untuk <i>role user</i> dan <i>admin</i> agar dapat berjalan dengan baik di setiap <i>browser</i> .
5	Registrasi Akun Baru	✓	✓	✓	✓	Memastikan fitur pembuatan akun baru berfungsi normal dan tidak ada kesalahan validasi <i>form</i> .
6	Unggah Citra Daun Pisang	✓	✓	✓	✓	Menguji proses <i>upload</i> gambar daun pisang pada halaman klasifikasi, memastikan <i>file</i> berhasil diproses

No	Jenis Pengujian	✓	✓	✓	✓	Keterangan
7	Hasil Klasifikasi	✓	✓	✓	✓	oleh model CNN. Memastikan hasil prediksi (<i>Cordana</i> , <i>Black Sigatoka</i> , <i>Yellow Sigatoka</i> , <i>Healthy</i> , atau <i>Non-banana</i>) tampil sesuai dengan probabilitas yang benar.
8	Lihat Riwayat Klasifikasi	✓	✓	✓	✓	Menguji tampilan tabel riwayat hasil klasifikasi serta memastikan data tersimpan dan muncul dengan benar.
9	Hapus Riwayat Klasifikasi	✓	✓	✓	✓	Menguji fungsi penghapusan hasil klasifikasi dan memastikan data terhapus dari <i>database</i> serta <i>file</i> .
10	Edit Profil Pengguna	✓	✓	✓	✓	Menguji perubahan data profil (nama, <i>email</i> , dan <i>password</i>) berjalan normal di setiap <i>browser</i> .
11	Dashboard Admin	✓	✓	✓	✓	Memastikan tampilan <i>dashboard</i> admin menampilkan data pengguna dan hasil klasifikasi secara <i>real time</i> .
12	Kelola Data Klasifikasi (Admin)	✓	✓	✓	✓	Menguji fungsi pencarian, penghapusan, dan penelusuran hasil klasifikasi oleh admin berjalan baik di setiap <i>browser</i> .
13	Kelola Data User (Admin)	✓	✓	✓	✓	Menguji fungsi tambah, edit, dan hapus data pengguna di halaman admin.
14	Logout Pengguna & Admin	✓	✓	✓	✓	Memastikan fungsi <i>logout</i> bekerja dengan baik, sesi pengguna diakhiri, dan diarahkan kembali ke halaman <i>login</i> .

Karena mayoritas pengguna lapangan menggunakan *smartphone*, dilakukan pula pengujian kompatibilitas pada browser *mobile* untuk memastikan stabilitas sistem ketika diakses melalui perangkat Android maupun iOS. Hasil pengujiannya ditampilkan pada Tabel 8 berikut.

Tabel 8. Pengujian Sistem pada *Browser Mobile*

No	Jenis Pengujian	Chrome (Android)	Firefox (Android)	Brave (Android)	Safari (iOS)	Keterangan
1	Tampilan Halaman	✓	✓	✓	✓	Sesuai
2	Responsif Halaman pada Berbagai Layar	✓	✓	✓	✓	Sesuai
3	Kompatibilitas <i>JavaScript</i>	✓	✓	✓	✓	Sesuai
4	Proses <i>Login</i> Pengguna	✓	✓	✓	✓	Sesuai
5	Registrasi Akun Baru	✓	✓	✓	✓	Sesuai
6	Unggah Citra Daun Pisang	✓	✓	✓	✓	Sesuai
7	Hasil Klasifikasi	✓	✓	✓	✓	Sesuai
8	Lihat Riwayat Klasifikasi	✓	✓	✓	✓	Sesuai
9	Hapus Riwayat Klasifikasi	✓	✓	✓	✓	Sesuai
10	Edit Profil Pengguna	✓	✓	✓	✓	Sesuai
11	<i>Dashboard</i> Admin	✓	✓	✓	✓	Sesuai
12	Kelola Data Klasifikasi (Admin)	✓	✓	✓	✓	Sesuai
13	Kelola Data <i>User</i> (Admin)	✓	✓	✓	✓	Sesuai
14	<i>Logout</i> Pengguna & Admin	✓	✓	✓	✓	Sesuai

Berdasarkan seluruh rangkaian pengujian *Black Box* yang dilakukan pada fitur inti, antarmuka pengguna, fungsi admin, serta kompatibilitas *browser* baik di *desktop* maupun perangkat *mobile*, dapat disimpulkan bahwa sistem bekerja secara konsisten dan sesuai dengan spesifikasi yang dirancang. Seluruh fungsi mulai dari autentikasi, unggah citra, proses klasifikasi oleh model CNN ResNet50V2, hingga pengelolaan data pengguna dan hasil klasifikasi dapat berjalan tanpa kendala baik pada berbagai jenis perangkat maupun browser.

3.6 Limitasi Penelitian

Meskipun penelitian ini telah menunjukkan hasil yang sangat baik dalam proses klasifikasi penyakit daun pisang menggunakan arsitektur ResNet50V2, masih terdapat beberapa keterbatasan yang perlu diperhatikan. Identifikasi terhadap limitasi penelitian penting dilakukan untuk memberikan gambaran yang lebih objektif mengenai ruang lingkup penelitian dan potensi pengembangan selanjutnya.

1. Variasi kondisi lingkungan pada dataset masih terbatas, karena seluruh citra dikumpulkan pada satu lokasi perkebunan sehingga belum mewakili perbedaan cahaya, cuaca, atau latar belakang dari wilayah lain.
2. Pengambilan citra diperoleh menggunakan kamera ponsel standar, sehingga performa model dapat berubah apabila digunakan pada kamera dengan kualitas rendah atau kondisi gambar yang sangat buram.
3. Penelitian hanya mengevaluasi satu arsitektur utama, yaitu ResNet50V2, sehingga belum terdapat perbandingan performa dengan model lain seperti EfficientNet, MobileNet, atau DenseNet.
4. Sistem hanya berfokus pada klasifikasi jenis penyakit, dan belum dilengkapi analisis lanjutan seperti tingkat keparahan penyakit atau rekomendasi tindakan bagi petani.
5. *Website* belum mendukung penggunaan secara *offline*, sehingga masih membutuhkan koneksi internet stabil untuk melakukan proses klasifikasi.

Dengan mempertimbangkan keterbatasan tersebut, penelitian lanjutan diharapkan dapat memperluas cakupan data, meningkatkan kemampuan generalisasi model, serta mengembangkan fitur tambahan pada sistem agar lebih adaptif terhadap kebutuhan petani di berbagai kondisi lingkungan.

6. Kesimpulan dan Saran

Berdasarkan hasil pengujian, implementasi metode *Convolutional Neural Network* (CNN) arsitektur ResNet50V2 terbukti mampu memberikan performa klasifikasi yang sangat baik dalam mendeteksi penyakit daun pisang berbasis citra digital. Model terbaik diperoleh pada rasio pembagian data 70:30, dengan jumlah 2.655 citra sebagai data latih, 569 citra sebagai data validasi, dan 569 citra sebagai data uji, serta jumlah *epoch* sebanyak 40. Model tersebut menghasilkan akurasi pelatihan dan validasi masing-masing sebesar 96%, dengan nilai *loss* 0.13 pada data pelatihan dan 0.15 pada data validasi. Hasil *confusion matrix* menunjukkan kemampuan generalisasi model yang kuat, ditandai dengan tingkat kesalahan klasifikasi yang rendah, terutama pada kelas *Healthy* dan *Non-Banana* yang mencapai tingkat ketepatan hingga 100%. Implementasi model pada sistem berbasis web menggunakan *framework* Flask juga menunjukkan kinerja yang baik, di mana pengguna dapat mengunggah citra daun pisang dan memperoleh hasil klasifikasi secara cepat, dan mudah melalui website.

Untuk pengembangan selanjutnya, disarankan agar dilakukan penambahan variasi dataset terutama pada kelas penyakit yang jumlah datanya masih terbatas, serta pengembangan versi *mobile* agar sistem dapat digunakan secara langsung di lapangan. Dengan pengembangan tersebut, diharapkan sistem klasifikasi penyakit daun pisang berbasis CNN ini dapat semakin optimal dan memberikan kontribusi nyata terhadap penerapan teknologi cerdas dalam sektor pertanian.

Daftar Pustaka

- [1] B. Hariyanto, I. Suliansyah, Y. Yusniwati, dan A. Sutanto, "Studi Karakter Morfologi dan Fisiologi Bibit Pisang Kepok Tanjung Daun Sempit dan Daun Normal dari Kultur Jaringan," *JURNAL TRITON*, vol. 16, no. 1, hlm. 82–94, Feb 2025, doi: 10.47687/jt.v16i1.1252.
- [2] M. D. Pratama, R. Gustriansyah, dan E. Purnamasari, "KLASIFIKASI PENYAKIT DAUN PISANG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN)," 2024.
- [3] R. Andera, Priyatningsih, dan M. Mutiara, "DETEKSI DAN IDENTIFIKASI PENYAKIT TANAMAN PISANG (MUSA ACUMINATA) OLEH CENDAWAN CORDANA MUSAE DENGAN BEBERAPA METODE," *Universitas Negeri Padang*, vol. 01, no. 2021, 2021, doi: 10.24036/prosemnasbio/vol1/90.
- [4] R. Ferdianysah, S. T. Arfian, R. Arrizal, O. Syah, dan T. Agustin, "KLASIFIKASI PENYAKIT DAUN PISANG BERBASIS CNN MENGGUNAKAN MODEL GLOBALAVERAGEPOOLING2D, AVERAGEPOOLING, DAN FLATTEN," Nov 2024.
- [5] J. Halim dan A. N. Fajar, "Klasifikasi Pisang Berbasis Algoritma VGG16 Melalui Metode CNN Deep Learning," Mei 2023.
- [6] M. S. A. Zakaria, A. Faisol, dan F. X. Ariwibisono, "Implementasi Convolutional Neural Network Untuk Deteksi Dan Klasifikasi Penyakit Tanaman Hias Berdasarkan Citra Daun," Des 2024, doi: 10.32509/wacana.v21i2.2000.
- [7] N. B. Pamungkas dan A. Suhendar, "Penerapan Metode Convolutional Neural Network pada Sistem Klasifikasi Penyakit Tanaman Apel berdasarkan Citra Daun," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, hlm. 675–684, Des 2024, doi: 10.29408/edumatic.v8i2.27958.
- [8] S. Maulana, "Deteksi Kesegaran Telur Ayam pada Citra Cangkang Menggunakan Metode Convolutional Neural Network (CNN)," Jun 2024.
- [9] C. Agusniar dan D. Adelia, "Penerapan Convolutional Neural Network pada Klasifikasi Jenis Ras Kucing

- Menggunakan ResNet50V2,” 2024.
- [10] H. Qonita, W. Laksono, dan D. Y. Priyandari, “Implementasi Deep Learning Menggunakan Metode Convolutional Neural Network untuk Mendeteksi Kehalalan pada Kosmetik,” vol. 22, no. 2, hlm. 67–75, 2023, doi: 10.20961/performa.22.2.76650.
- [11] A. Julianto, A. Sunyoto, D. Ferry, dan W. Wibowo, “OPTIMASI HYPERPARAMETER CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT TANAMAN PADI,” Yogyakarta, Des 2022.