



Identifikasi Penyakit Daun Mangga Menggunakan Teknik Pengolahan Citra dan Convolutional Neural Network

Rizki Sanria Prasetyo^{1*}, Agyztia Premana², Nur Ariesanto Ramdhan³

^{1,2,3} Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muahdi Setiabudi, Indonesia

Email: rsanriap34@gmail.com^{1*}, a.premana@umus.ac.id², nurasiesantoramdhan@umus.ac.id³

*Penulis Korespondensi: rizki@umus.ac.id

Abstract. *The detection of diseases in mango leaves is a significant challenge in Indonesia's agricultural sector, as it directly affects both the quality and quantity of crop yields. This study aims to develop an image-based classification system for mango leaf diseases using Convolutional Neural Network (CNN) architectures, namely VGG16 and Xception. The dataset used in this research consists of two different datasets. The first dataset includes two classes, healthy and diseased leaves, while the second dataset comprises three classes: Jelangga Fungus, Chlorosis, and Healthy. Data augmentation techniques and the Adam optimizer were applied to enhance model performance. Model evaluation was conducted using a confusion matrix along with precision, recall, and F1-score metrics. The experimental results indicate that VGG16 consistently achieves the best performance, with an accuracy of up to 100% in the two-class classification scenario and 99% in the three-class classification scenario. These findings demonstrate that CNN architectures, particularly VGG16, are effective and reliable for classifying mango leaf diseases based on digital images.*

Keywords: CNN; Data Augmentation; Deep Learning; Disease Detection; Mango Leaves.

Abstrak. Deteksi penyakit pada daun mangga merupakan salah satu tantangan penting dalam sektor pertanian Indonesia karena berpengaruh langsung terhadap kualitas dan kuantitas hasil panen. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi citra penyakit daun mangga menggunakan arsitektur Convolutional Neural Network (CNN), yaitu VGG16 dan Xception. Dataset yang digunakan terdiri atas dua set data yang berbeda. Dataset pertama mencakup dua kelas, yaitu daun sehat dan daun sakit, sedangkan dataset kedua terdiri dari tiga kelas, yaitu Jamur Jelangga, Klorosis, dan Sehat. Untuk meningkatkan performa model, diterapkan teknik augmentasi data serta penggunaan optimizer Adam. Evaluasi kinerja model dilakukan menggunakan Confusion Matrix serta metrik presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa arsitektur VGG16 secara konsisten memberikan performa terbaik, dengan tingkat akurasi mencapai 100% pada skenario klasifikasi dua kelas dan 99% pada skenario klasifikasi tiga kelas. Dengan demikian, arsitektur CNN, khususnya VGG16, terbukti efektif dan konsisten dalam mengklasifikasikan penyakit daun mangga berbasis citra digital.

Kata Kunci: Augmentasi Data; CNN; Daun Mangga; Deep Learning; Deteksi Penyakit.

1. PENDAHULUAN

Mangga (*Mangifera indica* L.) merupakan tanaman buah tahunan tropis yang berasal dari India dan termasuk dalam keluarga Anacardiaceae. Buah mangga memiliki kandungan vitamin A dan vitamin C yang tinggi, yang berperan penting dalam menjaga kesehatan mata, meningkatkan daya tahan tubuh, serta mendukung kesehatan secara umum. Selain nilai gizinya, mangga juga memiliki nilai ekonomi yang tinggi karena dapat diolah menjadi berbagai produk pangan dan menjadi salah satu komoditas hortikultura unggulan di Indonesia (Kurniawan & Prasetyo, 2019). Tingginya minat masyarakat dan petani terhadap budidaya mangga, baik untuk konsumsi pribadi maupun tujuan komersial, menjadikan tanaman ini memiliki peran strategis dalam sektor pertanian dan perekonomian lokal (E. Fitriani & Sari, 2020).

Dalam proses pembudidayaannya, tanaman mangga tidak terlepas dari berbagai tantangan, khususnya serangan hama dan penyakit. Penyakit tanaman mangga dapat disebabkan oleh jamur,

bakteri, virus, serta dipengaruhi oleh faktor lingkungan seperti perubahan suhu dan kelembapan yang ekstrem. Serangan penyakit tersebut dapat menghambat pertumbuhan tanaman, menurunkan kualitas daun dan buah, serta menyebabkan penurunan hasil panen secara signifikan apabila tidak ditangani dengan tepat (Fitriani et al., 2020). Salah satu penyakit penting pada tanaman mangga adalah antraknosa yang disebabkan oleh genus *Colletotrichum*, yang diketahui berdampak besar terhadap kualitas dan kuantitas hasil panen mangga (Purnamasari et al., 2018).

Identifikasi penyakit tanaman mangga selama ini masih banyak dilakukan secara manual melalui pengamatan visual oleh petani atau penyuluh pertanian. Pendekatan konvensional ini memiliki sejumlah keterbatasan, antara lain bersifat subjektif, membutuhkan pengalaman khusus, serta rentan terhadap kesalahan akibat kemiripan gejala antar penyakit. Keterlambatan dalam mendeteksi penyakit juga dapat menyebabkan penyebaran penyakit yang lebih luas dan meningkatkan risiko kerugian hasil panen (Nurchayati et al., 2022). Diperlukan pendekatan yang lebih objektif dan otomatis untuk membantu proses identifikasi penyakit tanaman mangga secara dini dan akurat (Utami et al., 2022).

Salah satu pendekatan yang banyak dikembangkan untuk mendukung identifikasi penyakit tanaman adalah pengolahan citra digital. Pengolahan citra digital memungkinkan informasi visual pada daun, seperti perubahan warna, tekstur, dan pola bercak, diekstraksi dan dianalisis secara komputasional untuk tujuan klasifikasi (H. Okten & Yuzgec, 2022). Dalam konteks penyakit daun mangga, teknik pengolahan citra berperan sebagai tahap awal (*preprocessing*) yang bertujuan meningkatkan kualitas citra sehingga ciri visual penyakit dapat dikenali dengan lebih jelas dan konsisten (Saputra et al., 2021).

Perkembangan *deep learning* mendorong pemanfaatan metode yang lebih canggih dalam klasifikasi citra, salah satunya adalah CNN. CNN merupakan arsitektur jaringan saraf yang dirancang khusus untuk memproses data citra dengan kemampuan mengekstraksi fitur secara otomatis melalui operasi konvolusi berlapis (Simhadri & Kondaveeti, 2023). Keunggulan CNN terletak pada kemampuannya mempelajari pola visual yang kompleks tanpa memerlukan perancangan fitur manual, sehingga sangat sesuai untuk mendeteksi penyakit daun yang memiliki variasi gejala yang beragam seperti pada daun mangga (A. Rasjava & Sharma, 2020).

Sejumlah penelitian terdahulu menunjukkan bahwa CNN berhasil diterapkan pada klasifikasi penyakit tanaman selain mangga. Penerapan CNN pada tanaman jagung mampu mencapai akurasi hingga 87% pada data latih dan 84% pada data uji dengan optimasi parameter tertentu (Nurchayati et al., 2022). Penelitian lain pada tanaman padi menggunakan arsitektur CNN berbasis Inception V3 juga menunjukkan performa yang baik dengan tingkat akurasi mencapai

93%, yang menegaskan potensi CNN dalam mendeteksi penyakit tanaman berbasis citra daun (Suhendar et al., 2023).

Dalam pengembangan sistem klasifikasi penyakit daun berbasis CNN, pemilihan arsitektur model menjadi faktor penting yang memengaruhi performa sistem. Arsitektur VGG16 dikenal memiliki struktur yang sederhana dan stabil, sehingga banyak digunakan sebagai model dasar dalam penelitian klasifikasi citra (Simonyan & Zisserman, 2015). Sementara itu, arsitektur Xception menggunakan pendekatan *depthwise separable convolution* yang lebih efisien secara komputasi dan mampu mempertahankan tingkat akurasi yang tinggi, sehingga berpotensi diterapkan pada sistem deteksi penyakit tanaman yang membutuhkan efisiensi dan kecepatan (Collier, 2020).

Masih terdapat riset gap pada penerapan CNN untuk penyakit daun mangga, khususnya terkait keterbatasan dataset lokal, perbandingan performa berbagai arsitektur CNN secara sistematis, serta evaluasi model yang komprehensif pada kondisi data yang beragam. Oleh karena itu, penelitian ini diarahkan untuk mengidentifikasi penyakit daun mangga menggunakan teknik pengolahan citra dan CNN dengan membandingkan beberapa arsitektur CNN guna memperoleh model yang paling optimal. Pendekatan ini diharapkan dapat memberikan kontribusi ilmiah sekaligus solusi praktis bagi petani dalam mendeteksi penyakit daun mangga secara dini dan akurat (Simhadri et al., 2024).

Penyakit Daun Mangga

Penyakit daun mangga merupakan salah satu faktor yang dapat menurunkan pertumbuhan dan hasil produksi tanaman mangga. Gejala penyakit umumnya terlihat pada daun berupa bercak, perubahan warna, dan kerusakan jaringan, yang dapat mengganggu proses fotosintesis tanaman (Purnamasari et al., 2018). Deteksi penyakit daun mangga secara dini sangat penting untuk mencegah penurunan kualitas dan kuantitas hasil panen (R. Fitriani & Hasanah, 2020).

Pengolahan Citra Digital

Pengolahan citra digital adalah teknik untuk memproses dan meningkatkan kualitas citra agar informasi penting dapat dianalisis secara komputasional. Dalam identifikasi penyakit daun mangga, pengolahan citra digunakan untuk menonjolkan ciri visual penyakit melalui tahapan *preprocessing* seperti *resizing*, normalisasi, dan peningkatan kontras (I. Okten & Yuzgec, 2022). Tahapan ini membantu sistem mengenali pola penyakit pada daun dengan lebih jelas (Saputra et al., 2021).

Convolutional Neural Network


CNN merupakan metode *deep learning* yang banyak digunakan untuk klasifikasi citra. CNN mampu mengekstraksi fitur secara otomatis melalui proses konvolusi berlapis, sehingga efektif

dalam mengenali pola visual pada daun tanaman (A. R. Rasjava et al., 2020). Metode ini sesuai untuk identifikasi penyakit daun mangga yang memiliki variasi gejala visual yang beragam (Simhadri & Kondaveeti, 2023).

CNN telah diterapkan pada berbagai tanaman dan menunjukkan hasil yang baik. Penelitian pada tanaman jagung dan padi membuktikan bahwa CNN mampu mencapai tingkat akurasi yang tinggi dalam mengklasifikasi penyakit daun (Nurchayati et al., 2022; Suhendar et al., 2023). Hasil tersebut menunjukkan bahwa CNN berpotensi diterapkan untuk identifikasi penyakit daun mangga. Beberapa arsitektur CNN umum digunakan dalam klasifikasi citra. VGG16 dikenal dengan struktur yang sederhana dan stabil, sehingga sering digunakan sebagai model dasar (Simonyan & Zisserman, 2015). Xception menawarkan efisiensi komputasi yang lebih baik dengan tetap mempertahankan akurasi model (Chollet, 2017).

2. METODOLOGI

Penelitian ini menggunakan pendekatan eksperimental kuantitatif untuk menganalisis dan membandingkan performa dua arsitektur *Convolutional Neural Network* (CNN), yaitu VGG16 dan Xception, dalam klasifikasi citra penyakit daun mangga. Pendekatan eksperimen dipilih karena memungkinkan evaluasi objektif terhadap kinerja model berdasarkan metrik kuantitatif seperti akurasi, presisi, recall, dan F1-score (Lu et al., 2021).



Gambar 1. Alur Metode Penelitian.

Gambar 1 merupakan diagram alur simulasi algoritma yang dimulai proses augmentasi, input data, CNN model, output Klasifikasi.

Pengumpulan Data

Dalam pengumpulan data ini dilakukan dengan mencari data daun mangga untuk mencari informasi terkait hama daun mangga dalam bentuk gambar dengan jumlah awal 579 dataset Sehat dan Sakit. Setelah itu data dilakukan augmentasi dari setiap gambar dikalikan dengan jumlah

augmentasi sehingga menghasilkan 2.887 dataset sakit dan Sehat. augmentasi data bertujuan untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting* pada proses pelatihan (Sharma et al., 2020; Okten & Yuzgec, 2022).

Tabel 1. Dataset Sehat dan Sakit.

Kelas	Data Awal	Flip H	Flip V	Rescalling	Rotasi	Zoom
Sakit						
Sehat						

Dalam pengumpulan dataset kedua yaitu data awal berjumlah 191 dataset jamur jelangga, klorosis, sehat, kemudian dilakukan augmentasi dari setiap gambar dikalikan jumlah augmentasi sehingga menghasilkan 943 dataset jamur jelangga, klorosis, sehat.

Augmentasi Data

Proses augmentasi data pada tabel 1 dan 2 merupakan teknik yang digunakan untuk meningkatkan keragaman dan jumlah data sampel yang tersedia tanpa perlu mengumpulkan data baru secara langsung. Teknik ini dilakukan dengan cara memodifikasi data yang sudah ada melalui berbagai augmentasi, seperti rotasi, *zoom*, *flipping*, *rescalling*. Tujuan utama dari augmentasi ini adalah untuk memperkaya variasi data latih agar model klasifikasi yang dibangun menjadi lebih robust, tidak mudah *overfitting*, dan mampu mengenali pola secara lebih umum dalam data yang beragam. Dalam pengumpulan dataset kedua yaitu data awal berjumlah 191 dataset jamur jelangga, klorosis, sehat, kemudian dilakukan augmentasi dari setiap gambar dikalikan jumlah augmentasi sehingga menghasilkan 943 dataset jamur jelangga, klorosis, sehat.

Input Data Daun Mangga

Setelah melalui proses *augmentasi*, gambar yang dihasilkan mengalami transformasi pada koordinat piksel dan nilai-nilai warnanya, yang kemudian direpresentasikan dalam bentuk *array* numerik untuk digunakan dalam model CNN. Pada proses rotasi, misalnya dengan rotasi 90° searah jarum jam, koordinat piksel pada setiap saluran warna R,G,B berubah, menghasilkan matriks baru yang merepresentasikan gambar yang telah diputar. Proses *flipping*, baik horizontal maupun vertikal, mengubah posisi piksel berdasarkan sumbu tertentu, di mana *flipping horizontal* membalik posisi piksel sepanjang sumbu x, sedangkan *flipping vertikal* membalik posisi piksel sepanjang sumbu y (Simhadri & Kondaveeti, 2023).

Tabel 2. Dataset Jamur Jelangga, Klorosis, Sehat.

Kelas	Data Awal	Flip H	Flip V	Rescaling	Rotasi
Jamur Jelangga					
Klorosis					
Sehat					

Selanjutnya, proses *zooming* memperbesar atau memperkecil gambar dengan faktor skala tertentu. Setelah itu, *rescaling* dilakukan untuk mengubah nilai piksel ke rentang 0 hingga 1 dengan membagi setiap nilai piksel dengan 255, yang bertujuan untuk mempermudah pemrosesan oleh model CNN. Hasil akhir dari semua proses *augmentasi* ini adalah gambar yang direpresentasikan sebagai tensor dengan dimensi tertentu, misalnya 3×3 untuk gambar kecil yang siap digunakan sebagai *input* pada model CNN untuk proses pelatihan atau prediksi.

CNN Model

Model CNN adalah inti dari proses klasifikasi gambar, yang bertugas mengolah data gambar hasil *augmentasi* seperti rotasi, *flipping*, *zooming*, dan *rescaling* untuk menghasilkan prediksi yang akurat[8]. Data gambar yang telah diubah menjadi tensor numerik dengan dimensi tertentu dimasukkan ke dalam CNN sebagai *input* 4x4. Proses dimulai dari lapisan konvolusi yang mengekstraksi fitur-fitur spasial lokal seperti pola tekstur daun, bentuk tepi, atau gejala penyakit menggunakan filter berukuran kecil, dengan rumus sebagai berikut.

$$\text{Feature Map}(i, j) = \sum_{m=1}^k \sum_{n=1}^k \text{Input}(i + m - 1, j + n - 1) \dots\dots\dots(1)$$

Keterangan:

k = ukuran kernel, dengan k=3 (kernel berukuran 3x3x3).

i,j = posisi awal kernel pada citra input.

Input (i+m-1,j+n-1) = nilai elemen citra input pada posisi tertentu.

Kernel (m,n) = nilai elemen kernel pada posisi (m,n)

Feature Map (i,j) = hasil ekstraksi fitur pada posisi (i,j)

Hasil konvolusi kemudian melewati fungsi *aktivasi ReLU* untuk menambahkan nonlinearitas dan menghilangkan nilai negatif, sehingga hanya informasi relevan yang dipertahankan, dengan rumus dan simulasi sebagai berikut :

$$ReLU(x) = \max(0, x) \dots \dots \dots (2)$$

Selanjutnya setelah *aktivasi ReLU*, lapisan *pooling* digunakan untuk menyederhanakan dimensi data tanpa kehilangan fitur penting, seperti struktur tulang daun atau bercak pada permukaan daun, dengan rumus dan simulasi sebagai berikut :

$$Pooling(i, j) = \max(Area) \dots \dots \dots (3)$$

Setelah itu, data yang telah diproses diubah menjadi vektor satu dimensi *flatten* untuk dimasukkan ke lapisan sepenuhnya terhubung *fully connected layer*, yang menggabungkan semua fitur yang diekstraksi menjadi pola global, dengan simulasi dan rumus berikut:

$$z = w \cdot x + b \dots \dots \dots (4)$$

Keterangan:


w: bobot (0.5).

x: nilai dari pooling

b: bias

Pada lapisan akhir, fungsi aktivasi seperti *softmax* mengubah hasil menjadi probabilitas untuk setiap kelas, misalnya daun sehat 90% atau daun terkena penyakit 10%.


Model dilatih menggunakan metode *backpropagation* untuk memperbarui bobot dan mengurangi error, dengan bantuan *optimizer* seperti *Adam* untuk mempercepat proses pembelajaran. Dengan kombinasi *augmentasi* data yang meningkatkan keragaman sampel dan kemampuan CNN dalam mengenali pola, model menjadi lebih baik terhadap variasi kondisi gambar.



Gambar 2. Arsitektur VGG16.

Arsitektur VGG16 merupakan model CNN yang terkenal karena kesederhanaannya dan kemampuannya untuk memberikan akurasi cukup tinggi pada berbagai tugas klasifikasi gambar. Model ini terdiri dari beberapa lapisan konvolusi bertumpuk yang menggunakan kernel berukuran 3×3 dan lapisan pooling untuk mengurangi dimensi data. Struktur Lapisan Konvolusi

menggunakan kernel 3×3 dengan *padding same* untuk mempertahankan ukuran fitur map. Aktivasi *ReLU* setelah setiap lapisan konvolusi. *Pooling max pooling* dengan ukuran 2×2 digunakan setelah beberapa blok konvolusi. *Fully Connected Layer* terdapat dua lapisan *fully connected* dengan 4096 unit dan satu lapisan output dengan jumlah unit sesuai jumlah kelas. *Softmax* digunakan di lapisan akhir untuk memberikan probabilitas bagi setiap kelas. Simulasi hasil untuk data *input* misalkan hasil *pooling* terakhir menghasilkan vektor $x=[1,0.8,0.5,\dots]$, dan bobot w serta bias b dihitung selama pelatihan, maka *output* dari lapisan *fully connected* dapat dirumuskan sebagai $z = w \cdot x + b$ dengan fungsi *softmax* contoh keluaran Daun Sehat: 85%, Daun Sakit 15%.



Gambar 3. Arsitektur Xception

Arsitektur Xception merupakan perluasan dari Inception, dengan fokus pada *separable depthwise convolution*, yang memungkinkan efisiensi komputasi tinggi. Model ini sangat baik dalam menangani data gambar kompleks. *Depthwise Separable Convolution* memisahkan konvolusi spasial dan *channel*, yang mengurangi jumlah parameter. *Residual Connections* digunakan untuk membantu stabilitas dan meningkatkan kemampuan belajar. Struktur Blok terdiri dari entri *flow*, *middle flow*, dan *exit flow*, dengan total 36 lapisan konvolusi. Simulasi proses pada data daun, fitur seperti bercak atau pola warna dapat diekstraksi lebih detail dengan *depthwise convolution*. Proses aktivasi dan *pooling* dilakukan secara efisien untuk menghasilkan probabilitas klasifikasi. Misalnya, *output* Daun Sehat: 92%, Daun Sakit: 8%.

Output Klasifikasi

Bagian *output* klasifikasi adalah tahap akhir dalam proses penggunaan model *Convolutional Neural Network* (CNN) untuk mengidentifikasi kategori gambar berdasarkan data yang diberikan. Setelah data melewati berbagai lapisan CNN, *output* berupa probabilitas untuk setiap kelas dihasilkan oleh lapisan terakhir, yang umumnya menggunakan fungsi aktivasi seperti *softmax*. Probabilitas ini menunjukkan tingkat keyakinan model terhadap setiap kelas, dan kelas dengan probabilitas tertinggi dipilih sebagai prediksi akhir. Sebagai contoh, jika model digunakan untuk mengklasifikasikan daun mangga, *output* dapat berupa beberapa kategori seperti daun sehat, daun sakit. Misalnya, untuk sebuah gambar daun yang diberikan, model menghasilkan probabilitas daun

sehat 85%, daun sakit 15%. Berdasarkan nilai probabilitas tertinggi, gambar tersebut diklasifikasikan sebagai Daun Sehat.

3. HASIL DAN PEMBAHASAN

Pada hasil dan pembahasan pengujian menggunakan 2 skenario yaitu yang pertama menggunakan menggunakan dataset Sehat dan Sakit, yang kedua menggunakan dataser Jamur Jelangga, Klorosis, Sehat. Berikut ini hasil dari setiap skenario pengujian:

Skenario 1 menggunakan dataset 3 kelas yaitu Jamur Jelangga, Klorosis, Sehat

Tabel 3. Perbedaan Hasil Pada Skenario 1.

Metrix	Kelas	Vgg16	Xception
Precision	Jamur	1.00	0.92
	Jelangga		
	Klorosis	1.00	0.95
	Sehat	0.97	1.00
Recall	Jamur	1.00	0.92
	Jelangga		
	Klorosis	0.98	0.95
	Sehat	1.00	1.00
F1-Score	Jamur	1.00	0.92
	Jelangga		
	Klorosis	0.99	0.95
	Sehat	0.98	1.00
Accuracy		0.99	0.96

Pada proses pengujian skenario 1 ini pada model VGG16 berdasarkan hasil evaluasi dari gambar yang telah diunggah, model CNN menunjukkan kinerja klasifikasi yang sangat baik terhadap tiga kelas citra daun, yaitu *Jamur Jelaga*, *Klorosis*, dan *Sehat*. *Confusion matrix* menunjukkan bahwa dari 24 data *Jamur Jelaga*, seluruhnya berhasil diklasifikasikan dengan benar. Untuk kelas *Klorosis*, dari 42 data, sebanyak 41 diklasifikasikan dengan benar, sementara hanya 1 data yang salah diklasifikasikan sebagai *Sehat*. Sedangkan untuk kelas *Sehat*, dari 28 data, semuanya berhasil diklasifikasikan dengan benar. Hasil ini diperkuat oleh *Classification report* yang menunjukkan nilai *precision*, *recall*, dan *f1-score* yang sangat tinggi di semua kelas. Kelas *Jamur Jelaga* mencatat nilai sempurna pada semua metrik *Precision* 1.00, *Recall* 1.00, *F1-Score* 1.00. Kelas *Klorosis* memperoleh *Precision* 1.00, *Recall* 0.98, dan *F1-Score* 0.99, sementara kelas *Sehat* memiliki *Precision* 0.97, *Recall* 1.00, dan *F1-Score* 0.98.

Akurasi keseluruhan model mencapai 99%, dengan nilai rata-rata presisi makro dan *f1-score* makro masing-masing sebesar 0.99. Ini menunjukkan performa yang seimbang dan cukup tinggi di semua kelas. Hal ini menandakan bahwa model cepat beradaptasi selama proses pelatihan dan

mampu mempertahankan generalisasi yang baik. Secara keseluruhan, model CNN ini terbukti efektif untuk tugas klasifikasi penyakit daun tanaman berbasis citra.

Pada model Xception menunjukkan performa klasifikasi yang kurang baik dalam mengenali tiga kelas kondisi daun tanaman, yaitu Jamur Jelaga, Klorosis, dan Sehat. *Confusion matrix* memperlihatkan bahwa dari 24 data Jamur Jelaga, sebanyak 22 data berhasil diklasifikasikan dengan benar, sedangkan 2 lainnya salah diklasifikasikan sebagai Klorosis. Kelas Klorosis, dari 42 data, sebanyak 40 data diklasifikasikan dengan tepat, dan 2 data salah diklasifikasikan sebagai Jamur Jelaga. Sementara itu, kelas Sehat menunjukkan hasil sempurna dengan seluruh 28 data diklasifikasikan dengan benar.

Hasil ini diperkuat oleh *classification report* menunjukkan nilai *precision*, *recall*, dan *f1-score* yang tinggi pada ketiga kelas, yaitu Jamur Jelaga (0.92), Klorosis (0.95), dan Sehat (1.00), dengan akurasi keseluruhan mencapai 96%. Nilai rata-rata makro untuk *precision*, *recall*, dan *f1-score* masing-masing adalah 0.96, mencerminkan keseimbangan performa model dalam mengklasifikasikan semua kelas. Tetapi ketika di *inputkan* data baru mengalami *overfitting* pada model Xception ini meskipun dari hasil evaluasi cukup baik.

Skenario 2 menggunakan dua kelas yaitu Sehat dan Sakit

Tabel 4. Perbedaan Hasil Pada Skenario 2.

Metrix	Kelas	Vgg16	Xception
Precision	Sakit	1.00	0.99
	Sehat	1.00	0.99
Recall	Sakit	1.00	0.99
	Sehat	1.00	0.99
F1-Score	Sakit	1.00	0.99
	Sehat	1.00	0.99
Accuracy		1.00	0.99

Berdasarkan pengujian skenario 2, model VGG16 dari hasil evaluasi menunjukkan performa yang sangat baik. Pada *Classification Report*, model memiliki nilai *precision*, *recall*, dan *f1-score* sebesar 1.00 untuk kedua kelas, yaitu sakit dan sehat. Model mampu mengklasifikasikan seluruh data uji secara sempurna tanpa kesalahan. Hal ini diperkuat oleh visualisasi *Confusion Matrix* yang menunjukkan bahwa dari total 288 data uji, terdiri atas 132 data sakit dan 156 data sehat, seluruh prediksi model tepat 100% tanpa adanya kesalahan klasifikasi.

Semua data sakit diprediksi dengan benar sebagai sakit, dan semua data sehat diprediksi dengan benar sebagai sehat. Grafik *training* dan *validation*, *loss* serta *accuracy* juga mendukung hasil tersebut. Meskipun terdapat sedikit fluktuasi pada awal pelatihan, baik *loss* maupun akurasi tetap stabil dan menunjukkan konvergensi yang baik. *Training* dan *validation loss* menurun

mendekati nol, sementara akurasi keduanya mencapai nilai 1.0. Titik terbaik (*best epoch*) terjadi pada epoch ke-44 untuk *loss* dan ke-3 untuk akurasi, yang menandakan bahwa model belajar dengan cepat dan efektif tanpa adanya *overfitting* yang signifikan. Secara keseluruhan, model VGG16 memiliki performa yang sangat baik dan mampu mengklasifikasikan data ke dalam dua kelas dengan optimal.

Berdasarkan hasil evaluasi menggunakan *classification report*, *confusion matrix*, serta grafik *training* dan *validation*, model menunjukkan performa yang tinggi dengan nilai *precision*, *recall*, dan *f1-score* sebesar 0.99 untuk kedua kelas, yaitu sakit dan sehat. Hal ini juga tercermin dari nilai akurasi keseluruhan sebesar 0.99. *Confusion matrix* menunjukkan bahwa model hanya melakukan dua kesalahan klasifikasi dari seluruh data uji, masing-masing satu kesalahan pada kelas sakit dan satu pada kelas sehat, yang mengindikasikan bahwa performa prediksi model tergolong cukup akurat.

Grafik *training* dan *validation loss* serta *training* dan *validation accuracy* menunjukkan adanya indikasi *overfitting*. Hal ini ditandai dengan nilai akurasi pelatihan dan validasi yang tinggi namun tidak stabil, serta adanya beberapa lonjakan pada grafik *validation loss*. Model cenderung terlalu cepat dalam proses pembelajaran, ditunjukkan dengan tercapainya akurasi maksimum pada epoch awal. Meskipun nilai *loss* terlihat kecil, fluktuasi yang cukup besar pada *validation loss* mengindikasikan bahwa model kurang mampu melakukan generalisasi terhadap data baru karena terlalu berfokus pada data pelatihan, sehingga kurang optimal dalam mengenali data yang belum pernah dilihat sebelumnya.

Meskipun model Xception memiliki performa evaluasi yang cukup baik, model ini perlu diwaspadai karena proses pembelajarannya yang terlalu cepat membuatnya rentan terhadap *overfitting*. Diperlukan strategi pencegahan *overfitting* seperti penerapan teknik *dropout*, augmentasi data, atau *early stopping* untuk meningkatkan kemampuan generalisasi model.

4. KESIMPULAN

Penelitian ini bertujuan untuk menganalisis dan membandingkan performa arsitektur Convolutional Neural Network (CNN) VGG16 dan Xception dalam mendeteksi penyakit daun mangga melalui citra digital. Berdasarkan hasil pengujian dan evaluasi model yang telah dilakukan, arsitektur VGG16 menunjukkan performa terbaik dengan nilai akurasi tertinggi sebesar 100,00%, sedangkan arsitektur Xception memperoleh akurasi tertinggi sebesar 99,00% pada skenario 2. Evaluasi menggunakan metrik *precision*, *recall*, dan *F1-score* semakin memperkuat bahwa VGG16 tidak hanya unggul dalam akurasi, tetapi juga memiliki konsistensi performa model yang sangat baik. Implementasi kedua arsitektur berhasil dilakukan menggunakan bahasa

pemrograman Python dan framework Streamlit, dengan proses klasifikasi yang berjalan secara efektif melalui tahapan *preprocessing*, augmentasi data yang meliputi rotasi, *zooming*, *flipping*, dan *rescaling*, serta pelatihan model menggunakan optimizer Adam. Berdasarkan hasil tersebut, dapat disimpulkan bahwa arsitektur VGG16 merupakan model yang paling optimal dalam mendeteksi penyakit daun mangga pada penelitian ini. Hasil penelitian ini diharapkan dapat dimanfaatkan dalam pengembangan sistem deteksi penyakit tanaman berbasis citra digital, khususnya untuk membantu petani dalam meningkatkan hasil panen dan kualitas produksi secara lebih efektif.

REFERENSI

- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1251–1258). <https://doi.org/10.1109/CVPR.2017.195>
- Collier, J. E. (2020). *Applied structural equation modeling using AMOS: Basic to advanced techniques*. Routledge. <https://doi.org/10.4324/9781003018414>
- Fitriani, E., & Sari, D. P. (2020). Identifikasi penyakit tanaman hortikultura berdasarkan gejala visual daun. *Media Pertanian*, 5(2).
- Fitriani, R., & Hasanah, N. (2020). Impact of plant diseases on mango production. *Asian Journal of Agriculture*. <https://doi.org/10.13057/asianjagric/g200104>
- Kurniawan, A., & Prasetyo, B. (2019). Economic and nutritional value of mango (*Mangifera indica* L.) as a leading tropical fruit. *Journal of Horticultural Research*. <https://doi.org/10.2478/johr-2019-0012>
- Nurchayati, N., Rahman, A., & Putri, S. R. (2022). Klasifikasi penyakit daun jagung menggunakan convolutional neural network. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(1). <https://doi.org/10.51901/jiifkom.v2i2.347>
- Okten, H., & Yuzgec, U. (2022). Digital image processing techniques for plant disease detection. *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.compag.2022.106822>
- Okten, I., & Yuzgec, U. (2022). Rice plant disease detection using image processing and probabilistic neural network. In *Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering (LNICST)* (Vol. 436, pp. 82–94). Springer. https://doi.org/10.1007/978-3-031-01984-5_7
- Purnamasari, R., Wiyono, S., & Widodo. (2018). Penyakit antraknosa pada tanaman mangga dan upaya pengendaliannya. *Jurnal Fitopatologi Indonesia*, 14(3).
- Rasjava, A. R., Sugiyarto, A. W., Kurniasari, Y., & Ramadhan, S. Y. (2020). Detection of rice plants diseases using convolutional neural network (CNN). *Proceeding International Conference on Science and Engineering*, 3, 393–396. <https://doi.org/10.14421/icse.v3.535>
- Rasjava, A., & Sharma, P. (2020). Convolutional neural networks for plant leaf disease classification. *Information Processing in Agriculture*. <https://doi.org/10.1016/j.inpa.2020.06.002>

- Saputra, R. A., Wasiyanti, S., Supriyatna, A., & Saefudin, D. F. (2021). Penerapan algoritma convolutional neural network dan arsitektur MobileNet pada aplikasi deteksi penyakit daun padi. *Swabumi*, 9(2), 184–188. <https://doi.org/10.31294/swabumi.v9i2.11678>
- Simhadri, C. G., & Kondaveeti, H. K. (2023). Automatic recognition of rice leaf diseases using transfer learning. *Agronomy*, 13(4). <https://doi.org/10.3390/agronomy13040961>
- Simhadri, C. G., Kondaveeti, H. K., Vatsavayi, V. K., Mitra, A., & Ananthachari, P. (2024). Deep learning for rice leaf disease detection: A systematic literature review on emerging trends, methodologies and techniques. *Information Processing in Agriculture*. <https://doi.org/10.1016/j.inpa.2024.04.006>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *arXiv Preprint arXiv:1409.1556*.
- Suhendar, S., Purnama, A., & Fauzi, E. (2023). Deteksi penyakit pada daun tanaman ubi jalar menggunakan metode convolutional neural network. *Jurnal Ilmiah Informatika Global*, 14(3), 62–67. <https://doi.org/10.36982/jiig.v14i3.3478>
- Utami, E., Rahmawati, D., & Suryani, L. (2022). Automated plant disease detection using digital image processing. *Jurnal Teknologi dan Sistem Informasi Pertanian*. <https://jurnal.polibatam.ac.id/index.php/JAIC>