

Deteksi Penyakit Daun Mangga Menggunakan Convolutional Neural Network Untuk Analisis Komperasi Arsitektur VGG16, Xception

^{1*}Ryo Ardiansyah, ²Made Ayu Dusea Widyadara, ³Umi Mahdyah

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: *¹ rioardiansah912@gmail.com, ²madedara@unpkediri.ac.id, ³umimahdiyah@gmail.com

Penulis Korespondens : Ryo Ardiansyah

Abstrak— Deteksi penyakit pada daun mangga merupakan tantangan penting dalam sektor pertanian Indonesia karena memengaruhi kualitas dan kuantitas hasil panen. Penelitian ini mengembangkan sistem klasifikasi citra penyakit daun mangga menggunakan arsitektur CNN VGG16 dan Xception. Dataset terdiri dari dua dataset berbeda yang pertama terdiri dari dua kelas yaitu kelas sehat dan sakit, dataset kedua memiliki tiga kelas yaitu Jamur Jelangga, Klorosis, dan Sehat. Teknik augmentasi data dan optimizer Adam digunakan untuk meningkatkan performa model. Evaluasi dilakukan dengan Confusion Matrix serta metrik presisi, recall, dan F1-score. Hasil menunjukkan bahwa VGG16 konsisten memberikan performa terbaik, dengan akurasi hingga 100% pada skenario dua kelas, dan 99% pada skenario tiga kelas. 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, VGG16, Xception

Abstract— Mango leaf disease detection is a critical challenge in the Indonesian agricultural sector because it affects the quality and quantity of the harvest. This study develops a mango leaf disease image classification system using CNN VGG16 and Xception architectures. The dataset consists of three scenarios of two classes healthy and sick, two diseases of Soil Fungus and Chlorosis, and three classes of Soil Fungus, Chlorosis, and Healthy. Data augmentation techniques and Adam optimizer are used to improve model performance. Evaluation is carried out using Confusion Matrix and precision, recall, and F1-score metrics. The results show that VGG16 consistently provides the best performance, with an accuracy of up to 100% in the two-class scenario, and 99% in the three-class scenario. CNN architecture, especially VGG16, is proven to be effective and consistent in classifying mango leaf diseases based on digital images.

Keywords— Data Augmentation, CNN, Mango Leaf, Deep Learning, Disease Detection, VGG16, Xception



I. PENDAHULUAN

Buah mangga (*Mangifera indica*) adalah tanaman buah tahunan tropis yang berasal dari India dan termasuk dalam keluarga *Anacardiaceae*. Buah ini kaya akan vitamin A dan C yang bermanfaat untuk menjaga kesehatan mata, meningkatkan daya tahan tubuh, serta meredakan gejala flu. Selain kaya gizi, mangga juga memiliki rasa yang lezat dan dapat diolah menjadi berbagai produk makanan, sehingga memiliki nilai ekonomi yang tinggi. Tidak heran jika

banyak petani maupun individu tertarik membudidayakan mangga, baik untuk keperluan pribadi maupun komersial [1].

Proses pembudidaya, tanaman mangga tidak terlepas dari tantangan, salah satunya adalah serangan hama dan penyakit. Beberapa jenis ancaman utama adalah serangga, infeksi bakteri, perubahan suhu ekstrem, jamur, dan virus. Serangan ini dapat menghambat pertumbuhan tanaman mangga dan menurunkan hasil panen. Kondisi ini memerlukan solusi yang lebih efektif, seperti sistem otomatis untuk mendeteksi penyakit pada tanaman mangga melalui teknologi pengolahan citra digital [2].

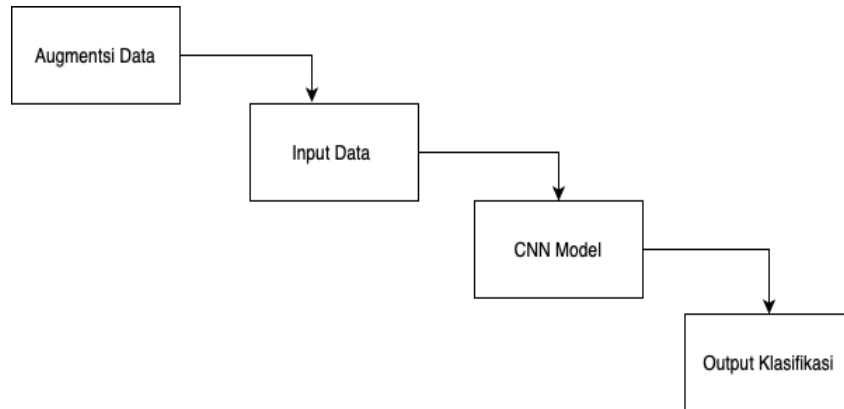
Pengolahan citra digital menjadi salah satu metode penting dalam mengidentifikasi penyakit tanaman. Proses utamanya adalah klasifikasi, yaitu memisahkan piksel atau objek pada gambar menjadi kelas-kelas tertentu. Salah satu pendekatan terbaik untuk klasifikasi gambar adalah *Convolutional Neural Network* (CNN), sebuah arsitektur *deep learning* yang dikenal karena tingkat akurasi yang tinggi. CNN mampu mempelajari pola kompleks dalam gambar secara otomatis, membuatnya ideal untuk mendeteksi penyakit pada daun mangga [3].

Penelitian terdahulu menunjukkan bahwa CNN baik untuk klasifikasi penyakit pada tanaman lain. Misalnya, dalam penelitian pada tanaman jagung, metode CNN dengan kernel 3x3 dan algoritma optimasi *Adaptive Moment Estimation* (Adam) menghasilkan akurasi hingga 87% pada data latih dan 84% pada data uji (Nurcahyati dkk., 2022). Studi lain pada tanaman padi menggunakan model berbasis Inception V3 mencapai akurasi hingga 93% dengan loss 30% (Suhendar dkk., 2023). Berdasarkan hasil tersebut, metode CNN memiliki potensi besar untuk diterapkan pada klasifikasi penyakit daun mangga.

Dalam pengembangan sistem berbasis CNN, pemilihan arsitektur model yang tepat sangat penting untuk mencapai hasil optimal. Berbagai arsitektur CNN, seperti VGG16, Xception, memiliki pendekatan berbeda dalam mempelajari pola citra. VGG16, yang dikenal dengan arsitektur berlapis sederhana, sering digunakan karena stabilitasnya[4], Xception merupakan model yang didesain dengan pendekatan *depthwise separable convolution*, sehingga mampu meningkatkan efisiensi tanpa mengorbankan akurasi[5]. Penelitian ini bertujuan untuk menganalisis dan membandingkan performa berbagai arsitektur CNN, seperti VGG16, Xception, dalam mendeteksi penyakit daun mangga. Fokus penelitian adalah mengevaluasi akurasi, waktu pelatihan, dan efisiensi model dalam mengidentifikasi gejala penyakit seperti bercak hitam atau kuning pada daun mangga.

II. METODE

Penelitian ini bertujuan untuk menganalisis dan membandingkan performa dua arsitektur Convolutional Neural Network (CNN), yaitu VGG16 dan Xception dalam tugas klasifikasi citra penyakit daun mangga. Kedua arsitektur tersebut dipilih karena memiliki karakteristik yang berbeda dalam hal kedalaman jaringan, efisiensi komputasi, dan kemampuan dalam mengekstraksi fitur kompleks dari citra. VGG16 dikenal sebagai arsitektur yang sederhana namun cukup baik dalam proses klasifikasi, Xception menawarkan efisiensi tinggi melalui penggunaan *depthwise separable convolution*[5]. Penelitian ini menggunakan pendekatan eksperimen untuk mengevaluasi kinerja masing-masing model dalam mengklasifikasikan citra daun mangga ke dalam kategori sehat dan sakit, termasuk jenis penyakit seperti jamur jelangga dan klorosis.















Gambar 1 Alur Metode

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

2.1 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.

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.

2.2 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.

Tabel 2 Dataset Jamur Jelangga, Klorosis, Sehat

Kelas	Data Awal	Flip H	Flip V	Rescalling	Rotasi	Zoom
Jamur Jelangga						
Klorosis						
Sehat						

2.3 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[7]. 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.

2.4 CNN Model

Model *Convolutional Neural Network* (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 :

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

Keterangan :

k=3 ukuran kernel (3×3×3).

i,j posisi awal kernel pada input.

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

Kernel(m,n) elemen kernel

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 :

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

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 :

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

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 sebagai berikut :

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


Keterangan:

w: bobot (0.5).

x: nilai dari pooling (12).

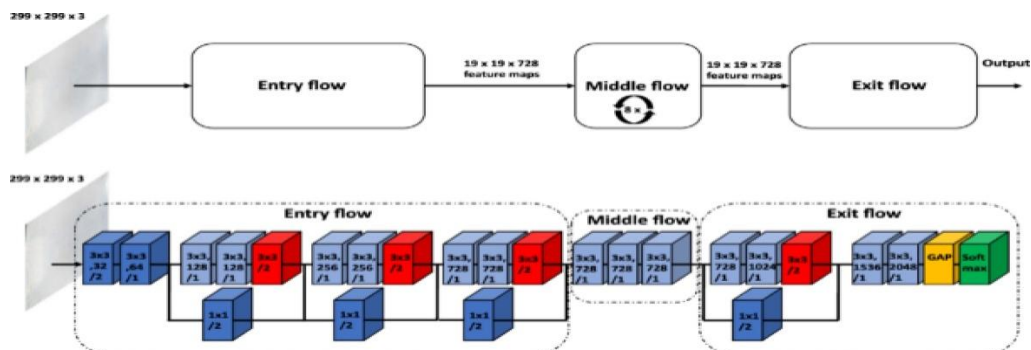
b: bias (1).

Pada lapisan akhir, fungsi aktivasi seperti *softmax* mengubah hasil menjadi probabilitas untuk setiap kelas, misalnya Daun sehat 90% atau Daun terkena penyakit 10%[9]. 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[10].



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 *entry 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%.

2.5 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.

III. HASIL DAN PEMBAHASAN

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

3.1 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
Recall	Sehat	0.97	1.00
	Jamur	1.00	0.92
	Jelangga		
F1-Score	Klorosis	0.98	0.95
	Sehat	1.00	1.00
	Jamur	1.00	0.92
Accuracy	Jelangga		
	Klorosis	0.99	0.95
	Sehat	0.98	1.00
		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. Untuk 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.

3.2 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

Dari pengujian skenario 2 model VGG16 dari hasil evaluasi menunjukkan hasil 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 dengan sempurna tanpa kesalahan. Hal ini diperkuat oleh visualisasi *Confusion Matrix* yang menunjukkan bahwa dari total 288 data uji 132 data *sakit* dan 156 data *sehat*, seluruh prediksi model tepat 100% tidak ada kesalahan klasifikasi. Semua data *sakit* diprediksi benar sebagai *sakit*, dan semua data *sehat* diprediksi 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* turun mendekati nol, sementara akurasi keduanya mencapai 1.0. Titik terbaik *best epoch* terjadi pada *epoch* ke-44 untuk *loss* dan ke-3 untuk

akurasi, menandakan model belajar dengan cepat dan efektif tanpa *overfitting* yang signifikan. Secara keseluruhan, model VGG16 memiliki performa yang cukup baik dan dapat mengklasifikasikan data ke dalam dua kelas dengan baik.

Model Xception Berdasarkan hasil evaluasi menggunakan *classification report*, *confusion matrix*, dan 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 dilihat dari 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 sehat, yang menunjukkan performa prediksi yang cukup akurat. Grafik *training* dan *validation loss* serta *training* dan *validation accuracy*, terlihat adanya indikasi *overfitting*. Hal ini ditandai dengan nilai akurasi pelatihan dan validasi yang tinggi namun tidak stabil, serta beberapa lonjakan yang terjadi pada grafik *loss validation*. Model terlalu cepat dalam proses pembelajarannya yang mencapai akurasi maksimum pada *epoch* awal, dan meskipun *loss* terlihat kecil, fluktuasi besar pada *validation loss* menunjukkan bahwa model kurang mampu menerima terhadap data baru dengan terlalu berfokus terhadap data pelatihan sehingga kurang mampu menerima data yang belum pernah dilihat sebelumnya. Model Xception ini meskipun performa evaluasi cukup baik, model Xception ini perlu diwaspadai karena dalam proses pembelajarannya dia terlalu cepat menjadi rawan akan *overfitting*. Perlu dilakukan strategi pencegahan *overfitting* seperti penggunaan teknik *dropout*, *augmentasi* data, atau *early stopping* untuk meningkatkan kemampuan model.

IV.KESIMPULAN

Penelitian ini bertujuan untuk menganalisis dan membandingkan performa arsitektur CNN VGG16 dan Xception, dalam mendeteksi penyakit daun mangga melalui citra digital. Berdasarkan hasil pengujian dan evaluasi model yang telah dilakukan model VGG16 menunjukkan performa terbaik dengan akurasi tertinggi sebesar 1.00%, sedangkan Xception akurasi tertinggi 99,00% pada scenario 2. Evaluasi menggunakan metrik seperti presisi, recall, dan F1-score memperkuat bahwa VGG16 tidak hanya unggul dalam akurasi, tetapi juga dalam konsistensi performa model. Implementasi kedua arsitektur berhasil dilakukan menggunakan bahasa pemrograman Python dan framework Streamlit, dengan proses klasifikasi yang berjalan efektif melalui tahapan preprocessing, augmentasi data (rotasi, zooming, flipping, dan rescaling), serta pelatihan model menggunakan optimizer Adam. Oleh karena itu, dapat disimpulkan bahwa VGG16 merupakan arsitektur 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 meningkatkan hasil panen dan kualitas produksi secara efektif.

DAFTAR PUSTAKA

- [1] Adenia, R., Minarno, A. E., & Azhar, Y. (2024). Implementasi Convolutional Neural Network Untuk Ekstraksi Fitur Citra Daun Dalam Kasus Deteksi Penyakit Pada Tanaman Mangga Menggunakan Random Forest. *Jurnal Repositor*, 4(4), 473–482. <https://doi.org/10.22219/repositor.v4i4.32287>

- [2] Akram, A., Fayakun, K., & Ramza, H. (2023). Klasifikasi Hama Serangga pada Pertanian Menggunakan Metode Convolutional Neural Network. *Building of Informatics, Technology and Science (BITS)*, 5(2), 397–406. <https://doi.org/10.47065/bits.v5i2.4063>
- [3] Alfarizi, M. R. S., Al-farish, M. Z., Taufiqurrahman, M., Ardiansah, G., & Elgar, M. (2023). Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning. *Karya Ilmiah Mahasiswa Bertauhid (KARIMAH TAUHID)*, 2(1), 1–6.
- [4] Alwanda, M. R., Ramadhan, R. P. K., & Alamsyah, D. (2020). Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle. *Jurnal Algoritme*, 1(1), 45–56. <https://doi.org/10.35957/algoritme.v1i1.434>
- [5] Ambarwari, A., Husni, E. M., & Mahayana, D. (2023). Perkembangan Paradigma Metode Klasifikasi Citra Penginderaan Jauh dalam Perspektif Revolusi Sains Thomas Kuhn. *Jurnal Filsafat Indonesia*, 6(3), 465–473. <https://doi.org/10.23887/jfi.v6i3.53865>
- [6] Vierisyah, A., Tasmi, & Fajri, R. M. (2023). Klasifikasi Kanker Paru Paru Menggunakan Cnn Dengan 5 Arsitektur. *Journal of Intelligent Networks and IoT Global*, 1(2), 84–91. <https://doi.org/10.36982/jinig.v1i2.3643>
- [7] Fuadi, A., & Suharso, A. (2022). Perbandingan Arsitektur Mobilenet Dan Nasnetmobile Untuk Klasifikasi Penyakit Pada Citra Daun Kentang. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(3), 701–710. <https://doi.org/10.29100/jupi.v7i3.3026>
- [8] Kurniawan, R., Wintoro, P. B., Mulyani, Y., & Komarudin, M. (2023). Implementasi Arsitektur Xception Pada Model Machine Learning Klasifikasi Sampah Anorganik. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(2), 233–236. <https://doi.org/10.23960/jitet.v11i2.3034>
- [9] Ambarwari, A., Husni, E. M., & Mahayana, D. (2023). Perkembangan Paradigma Metode Klasifikasi Citra Penginderaan Jauh dalam Perspektif Revolusi Sains Thomas Kuhn. *Jurnal Filsafat Indonesia*, 6(3), 465–473. <https://doi.org/10.23887/jfi.v6i3.53865>
- [10] Farij Amrulloh, M., Pamungkas, D. P., Kunci-Daun Bawang, K., Klasifikasi, ;, Cnn, ;, Xception, ;, & Amrulloh, M. F. (2024). Klasifikasi Penyakit Daun Bawang Menggunakan Algoritma CNN Xception Penulis Korespondensi. *Agustus*, 8, 2549–7952.