

Perbandingan Kinerja MobileNetV2 dan VGG16 dalam Klasifikasi Penyakit pada Citra Daun Tanaman Cabai

Its'naini Irvina Khoirunnisa ^{(1)*}, Abdul Fadlil ⁽²⁾, Herman Yuliansyah ⁽³⁾

¹ Departemen Magister Informatika, Universitas Ahmad Dahlan, Yogyakarta, Indonesia

² Departemen Teknik Elektro, Universitas Ahmad Dahlan, Yogyakarta, Indonesia

³ Departemen Informatika, Universitas Ahmad Dahlan, Yogyakarta, Indonesia

e-mail : its'nainiirvina@gmail.com, fadlil@mti.uad.ac.id, herman.yuliansyah@tif.uad.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 13 Maret 2025, direvisi 24 Juni 2025, diterima 7 Juli 2025, dan dipublikasikan 25 Januari 2026.

Abstract

Chili peppers play a crucial role in the Indonesian economy, serving as a significant source of income for many farmers. Price fluctuations influenced by weather conditions make this crop vulnerable to diseases that can impact productivity. However, leaves are key indicators of plant health, revealing early disease symptoms before they spread. This research focuses on detecting diseases in chili plants using neural network architectures via transfer learning, specifically MobileNetV2 and VGG16, to classify chili leaf images. The study aims to identify three disease classes: begomovirus, leaf spots, and healthy leaves. The dataset comprises 3,150 leaf images, split into 70% for training and 30% for testing. Results show that MobileNetV2 achieved an accuracy of 99.47% and VGG16 98.62%, with evaluation using a confusion matrix indicating good performance in disease identification, where MobileNetV2 offers better computational efficiency. Thus, transfer learning can effectively identify leaf diseases in chili plants.

Keywords: *Chili Diseases, Deep Learning, Image Classification, Neural Network, Transfer Learning*

Abstrak

Cabai memiliki peranan penting dalam perekonomian Indonesia dan menjadi sumber pendapatan bagi banyak petani. Fluktuasi harga cabai yang sering dipengaruhi oleh faktor cuaca membuat tanaman ini rentan terhadap penyakit, yang dapat berakibat signifikan terhadap penurunan produktivitas. Namun, daun menjadi indikator utama kesehatan tanaman karena menunjukkan gejala awal penyakit sebelum menyebar ke bagian lain. Penelitian ini bertujuan untuk mengusulkan model deteksi penyakit pada tanaman cabai berdasarkan citra daun menggunakan arsitektur *neural network* melalui pendekatan *transfer learning*, khususnya MobileNetV2 dan VGG16. Dalam penelitian ini, terdapat tiga kelas penyakit yang akan dideteksi, yaitu begomovirus, bercak daun, dan daun sehat. Dataset yang digunakan terdiri dari 3.150 citra daun, yang dibagi menjadi 70% data *training* dan 30% data *testing*. Hasil menunjukkan MobileNetV2 mencapai akurasi 99.47% dan VGG16 98.62% dengan evaluasi menggunakan *confusion matrix* yang mengindikasikan kinerja baik dalam identifikasi penyakit, di mana MobileNetV2 menawarkan efisiensi waktu komputasi yang lebih baik. Dengan demikian, *transfer learning* dapat berperan penting dalam mencapai hasil optimal dalam mengidentifikasi penyakit daun tanaman cabai.

Kata Kunci: *Penyakit Cabai, Deep Learning, Klasifikasi Gambar, Neural Network, Transfer Learning*

1. PENDAHULUAN

Indonesia dikenal sebagai negara agraris, sehingga masyarakatnya masih bergantung pada sektor pertanian untuk memenuhi kebutuhan hidup. Salah satu komoditas pertanian yang signifikan di Indonesia adalah cabai (Ramadhani et al., 2023). Cabai adalah tanaman yang memiliki peran penting dan ditanam di berbagai belahan dunia karena manfaatnya dalam kuliner dan sebagai obat (Siddiqui, 2023). Terdapat berbagai varietas tanaman cabai, salah satunya adalah cabai rawit (*Capsicum frutescens* L.). Berdasarkan Pusat Data dan Sistem Informasi



Artikel ini didistribusikan mengikuti lisensi Atribusi-NonKomersial CC BY-NC sebagaimana tercantum pada <https://creativecommons.org/licenses/by-nc/4.0/>.

Pertanian, rata-rata konsumsi cabai rawit di Indonesia pada tahun 2023 mencapai 2,192 kg per kapita per tahun, menunjukkan peningkatan sebesar 5,76% dibandingkan dengan tahun sebelumnya (Sekretariat Jenderal Kementerian Pertanian, 2023).

Cabai rawit termasuk sayuran yang mengalami fluktuasi harga yang signifikan, sehingga berpengaruh terhadap tingkat inflasi (K. Prasetyo et al., 2023). Fluktuasi harga tersebut dipicu oleh berbagai faktor, salah satunya adalah kondisi cuaca (Andini et al., 2024). Menanam cabai pada musim hujan dapat menghadapi tantangan cuaca yang berisiko bagi pertumbuhan tanaman. Curah hujan yang tinggi dan kelembaban udara yang meningkat dapat menyebabkan munculnya penyakit pada tanaman cabai rawit, seperti busuk buah antraknosa (*Colletotrichum sp.*), virus kuning (*Begomovirus*), virus mosaik, dan bercak daun (Syukur, 2018). Upaya untuk mengidentifikasi penyakit secara dini penting untuk meningkatkan ketahanan pangan nasional.

Penyakit cabai rawit yang tidak terdeteksi dan dibiarkan berkembang dapat menyebabkan kerusakan pada tanaman. Hal ini berpotensi menurunkan kualitas dan kuantitas panen cabai rawit, yang dapat berdampak negatif pada perekonomian negara (Ramadhani et al., 2023). Beberapa penelitian terdahulu telah mengevaluasi kualitas cabai berdasarkan daun, tanah, kandungan air, dan suhu (Pramudhita et al., 2023). Namun, kerugian yang dialami petani akibat kurangnya kemampuan dalam mengidentifikasi dan menangani penyakit tanaman cabai rawit secara dini tidak hanya berdampak pada pendapatan, tetapi juga dapat memengaruhi ketahanan pangan nasional. Adanya fluktuasi harga dan tantangan cuaca, penting untuk menemukan solusi yang efektif untuk mendeteksi penyakit ini secara otomatis.

Berdasarkan permasalahan yang ada, diperlukan solusi untuk memudahkan petani cabai dalam mengklasifikasikan penyakit tanaman cabai. Pemanfaatan teknik *deep learning* dan pemrosesan citra dapat memberikan jawaban untuk masalah ini. Beberapa tahun terakhir, telah muncul berbagai metode otomatis untuk membantu petani dalam mengidentifikasi jenis penyakit yang menyerang tanaman cabai. Salah satu proyek penelitian paling populer dalam klasifikasi penyakit tanaman adalah penggunaan pendekatan *deep learning*, khususnya *Convolutional Neural Network* (CNN), karena efisien dalam menghemat waktu dan hemat biaya (Pramudhita et al., 2023).

Terdapat beberapa penelitian sebelumnya yang membahas klasifikasi penyakit tanaman cabai. Ramadhani et al. (2023) membandingkan kemampuan CNN dan MobileNetV2 dalam mengklasifikasikan penyakit pada tanaman cabai. Hasil penelitian menunjukkan MobileNetV2 mencapai akurasi 90% yang lebih optimal dibandingkan dengan model CNN. Gulzar (2023) melakukan klasifikasi citra buah menggunakan TL-MobileNetV2 melalui teknik *transfer learning* untuk mengidentifikasi 40 jenis buah. Model TL-MobileNetV2 menunjukkan akurasi 99% lebih tinggi dibandingkan MobileNetV2. Maftukhah et al. (2024) melakukan klasifikasi citra kupu-kupu menggunakan CNN dengan arsitektur AlexNet. Model tersebut menunjukkan peningkatan akurasi seiring dengan ukuran citra yang lebih besar.

Alkanan & Gulzar (2024) melakukan klasifikasi penyakit biji jagung menggunakan *deep learning* arsitektur MobileNetV2. Model yang diusulkan mencapai akurasi sekitar 96% menunjukkan performa yang baik dibandingkan dengan model lainnya. Winiarti & Khoirunnisa (2024) melakukan deteksi penyakit cabai menggunakan aplikasi *mobile*, di mana model MobileNetV2 memperoleh akurasi 94%. Membuktikan CNN efektif dalam memproses gambar beresolusi kecil tanpa kehilangan informasi penting. Nguyen et al. (2022) mengklasifikasikan penyakit daun tomat menggunakan VGG-19 untuk mendeteksi penyakit secara akurat dan meningkatkan hasil panen. Hasil penelitian menunjukkan akurasi sebesar 99,72% dalam mengklasifikasikan citra daun tomat, serta mengurangi waktu pelatihan secara signifikan. Muis et al. (2024) melakukan klasifikasi citra tumor otak menggunakan pendekatan CNN menggunakan arsitektur AlexNet dan GoogLeNet. Temuan ini membantu mengurangi beban komputasi saat pelatihan model.

Tujuan penelitian ini adalah mengoptimalkan arsitektur model dalam mengidentifikasi penyakit pada citra daun tanaman cabai. Daun merupakan bagian tanaman yang responsif terhadap

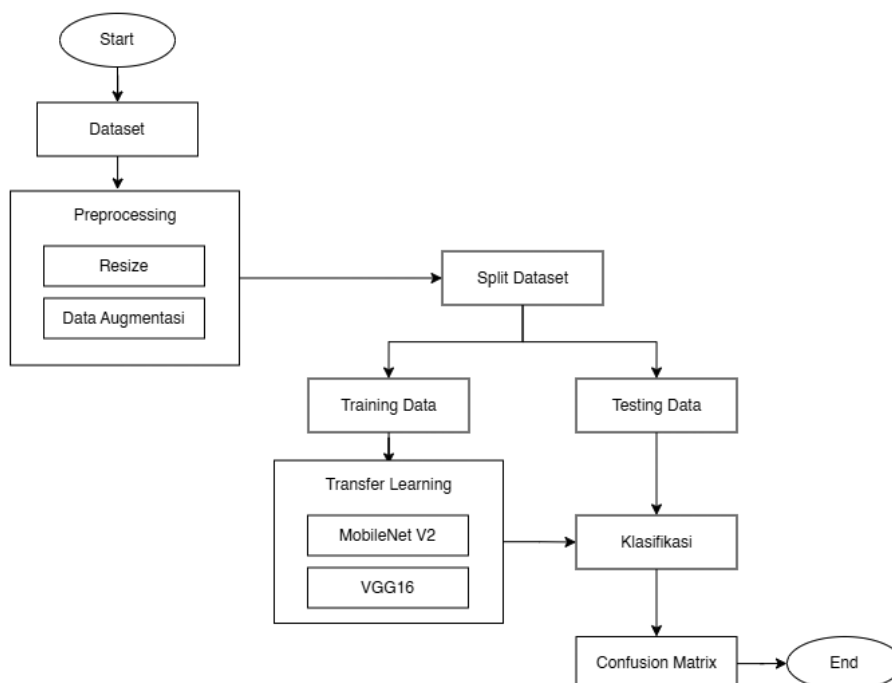


perubahan iklim (Y. Li et al., 2020) dan serangan patogen (Mostafa et al., 2022). Gejala penyakit cabai umumnya muncul pertama kali pada daun sebelum menyebar ke bagian lain seperti batang atau buah (Rustanto et al., 2024). Penelitian ini menerapkan metode CNN melalui pendekatan *transfer learning* dengan pemanfaatan arsitektur yang telah dilatih sebelumnya pada dataset besar. Penelitian ini tidak hanya meningkatkan akurasi dan efisiensi dalam klasifikasi citra, tetapi juga menghemat waktu dan sumber daya dalam pengembangan model.

Berdasarkan informasi yang diberikan, sangat penting untuk mengidentifikasi secara akurat jenis penyakit yang menyerang tanaman cabai sedini mungkin. Hal ini penting untuk memastikan bahwa penyakit ditangani dengan cepat dan akurat, mencegahnya menyebar ke tanaman lain di sekitarnya dan mengurangi risiko gagal panen. Oleh karena itu, penelitian ini bertujuan untuk meningkatkan konsep pemrosesan gambar digital dengan memanfaatkan *transfer learning*.

2. METODE PENELITIAN

Penelitian ini dimulai dari tahapan yang ditunjukkan pada Gambar 1 yang menjelaskan pengumpulan data. Kemudian *pre-processing* dilakukan dengan mengubah ukuran citra dan melakukan penambahan data. Dataset tersebut dibagi menjadi dua bagian yaitu data *training* dan data *testing*. Selanjutnya, memilih model berdasarkan arsitektur MobileNetV2 dan VGG16. Proses berikutnya adalah *training* model, kemudian model tersebut disimpan dan dilakukan *testing* model. Model dari masing-masing arsitektur kemudian dibandingkan berdasarkan hasil evaluasi untuk menentukan model yang terbaik.




Gambar 1 Metode Klasifikasi Penyakit Daun Tanaman Cabai

2.1 Dataset

Citra yang digunakan dalam penelitian ini berasal dari dataset citra daun penyakit tanaman cabai. Citra yang digunakan adalah citra berwarna RGB dalam format JPG. Penelitian ini difokuskan pada daun yang terinfeksi oleh berbagai jenis penyakit, antara lain virus kuning *begomovirus*, penyakit ini disebabkan oleh virus yang menyebar dengan cepat melalui serangga vektor seperti kutu kebul (*Bemisia tabaci*). Hal ini mengakibatkan tanaman cabai menjadi tidak produktif dan tidak menghasilkan buah (Syukur, 2018). Bercak daun antraknosa muncul sebagai bercak-bercak berwarna pucat yang awalnya kecil dan perlahan membesar (A. D. Prasetyo & Agustinar, 2022).



Bagian tengah bercak berwarna putih muda, sedangkan tepinya lebih gelap. Bercak yang sudah tua dapat menyebabkan terbentuknya lubang. Setelah terinfeksi, daun akan layu dan rontok. Virus *mosaic* ditandai dengan pola belang-belang hijau muda dan tua pada daun, yang mengakibatkan ukuran daun menjadi lebih kecil. Akibatnya, tanaman tidak dapat tumbuh dengan baik bahkan tidak mampu berproduksi sama sekali (Syukur, 2018). Kumpulan data yang digunakan dalam penelitian ini sebanyak 3.150 citra yang dibagi menjadi tiga kelas, di mana masing-masing kelas terdiri dari 1.050 citra. Kumpulan data ditunjukkan pada Gambar 2.



Gambar 2 Contoh Dataset Tanaman Cabai

2.2 Preprocessing Data

Preprocessing adalah proses yang dilakukan sebelum memulai *training* model. Pada tahap ini, citra digital diproses untuk meningkatkan kualitasnya, sehingga menghasilkan hasil yang lebih optimal saat data digunakan dalam pelatihan model (Singh et al., 2021). Preprocessing terdiri dari dua tahap yaitu *resize* dan *augmentasi* data. Pada tahap *resize*, ukuran citra diubah menjadi resolusi yang lebih kecil supaya prosesnya lebih efisien (Pramudhita et al., 2023). *Resize* dilakukan dengan menyamakan ukuran piksel dalam citra dan mengubah dimensi citra asli menjadi 300×300 piksel. Setelah proses *resize*, dilakukan *augmentasi* data untuk kemudian diperbanyak menggunakan *ImageDataGenerator* dengan menerapkan *flipping* vertikal dan horizontal, *cropping* citra, dan *zoom* citra untuk meningkatkan jumlah data.

2.3 Pembagian Data

Pembagian dataset dilakukan dengan 70% untuk data *training* dan 30% untuk data *testing*, sehingga model dapat dilatih dengan cukup data dan juga dievaluasi secara efektif menggunakan data yang terpisah untuk mengukur kinerjanya. Pada tahap *training* model, dilakukan inisialisasi untuk mengatur parameter seperti *learning rate* dan *optimizer* Adam (*Adaptive Moment Estimation*). Model dilatih menggunakan *training* data untuk menghitung prediksi dan *loss*, kemudian dihitung dengan membandingkan prediksi dengan label sebenarnya. Proses ini diulang selama *n epoch* hingga model mencapai performa yang memuaskan. Setelah *training* selesai, model disimpan untuk digunakan *testing* model, sehingga menghindari kebutuhan untuk melatih ulang model setiap kali ingin melakukan prediksi. Tahap selanjutnya *testing* model, di mana model yang telah dilatih sebelumnya digunakan untuk melakukan prediksi pada data *testing*. Proses ini mirip dengan *training* tetapi tidak ada pembaruan bobot. Data *testing* tidak digunakan selama *training*, sehingga tahap ini bertujuan untuk menguji kemampuan model dalam melakukan deteksi penyakit daun tanaman cabai.


2.4 Pemilihan Model

Pemilihan model dilakukan untuk menentukan arsitektur yang paling efektif dalam mengidentifikasi penyakit pada daun tanaman cabai. Proses ini melibatkan evaluasi berbagai arsitektur model yang ada, seperti MobileNetV2 dan VGG16. Tujuan utama dari pemilihan model ini adalah untuk memaksimalkan hasil akurasi klasifikasi, sehingga model dapat secara akurat mendeteksi dan mengklasifikasikan berbagai jenis penyakit yang mungkin menyerang tanaman cabai. Selain itu, waktu komputasi pelatihan juga menjadi pertimbangan dalam tahap ini.



2.4.1 MobileNetV2


MobileNetV2 adalah jenis *neural network* berbasis *mobile* yang digunakan untuk menangani kebutuhan sumber daya komputer yang berlebihan. Ketebalan filter di MobileNetV2 disesuaikan dengan ketebalan gambar *input* (Ramadhani et al., 2023). Arsitektur ini merupakan pengembangan dari konsep MobileNetV1. Meskipun MobileNetV2 membutuhkan waktu komputasi lebih lama dibandingkan MobileNetV1, arsitektur ini tetap mampu mencapai akurasi yang lebih tinggi. Gambar 3 menunjukkan arsitektur MobileNetV2.



Gambar 3 Arsitektur MobileNetV2

2.4.2 VGG16

VGG16 adalah jenis *neural network* yang terdiri dari 16 lapisan konvolusional, terbagi menjadi 11 lapisan konvolusional dan lima lainnya. Ukuran gambar *input* ditetapkan pada 224×224 piksel (Paymode & Malode, 2022). Menggunakan filter kecil (3×3) untuk menangkap fitur detail secara efektif, dan memiliki struktur yang dalam untuk meningkatkan kemampuan klasifikasi citra. Gambar 4 menunjukkan arsitektur VGG16.



Gambar 4 Arsitektur VGG16

2.5 Klasifikasi

Klasifikasi dilakukan untuk memproses model yang telah dilatih supaya dapat memprediksi kelas dari data uji dengan akurasi tinggi. Proses klasifikasi memungkinkan model untuk mengidentifikasi dan mengkategorikan data citra berdasarkan fitur-fitur tertentu yang telah dipelajari selama pelatihan. Sehingga model dapat mengenali berbagai jenis penyakit yang menyerang tanaman.

2.6 Evaluasi Kinerja Model

Hasil evaluasi model akan ditampilkan dalam bentuk *confusion matrix* yang digunakan untuk menghitung nilai akurasi, presisi, *recall*, dan F1-score (Hicks et al., 2022). Hal ini bertujuan untuk menilai seberapa baik model melakukan klasifikasi pada dataset yang digunakan. Pers. (1) digunakan untuk menghitung nilai akurasi, yang memberikan gambaran jelas tentang seberapa baik model dalam melakukan klasifikasi dengan benar. Pers. (2) digunakan untuk menghitung presisi, yang mengukur tingkat ketepatan sistem dalam mengklasifikasikan data sesuai dengan label yang seharusnya. Pers. (3) digunakan untuk menghitung *recall*, yang mengukur seberapa efektif model dalam mengurangi jumlah FN. Pers. (4) digunakan untuk menghitung F1-score, yang digunakan untuk melihat perbandingan rata-rata antara presisi dan *recall* sehingga memberikan gambaran menyeluruh tentang kinerja model.

$$\text{akurasi (\%)} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$



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

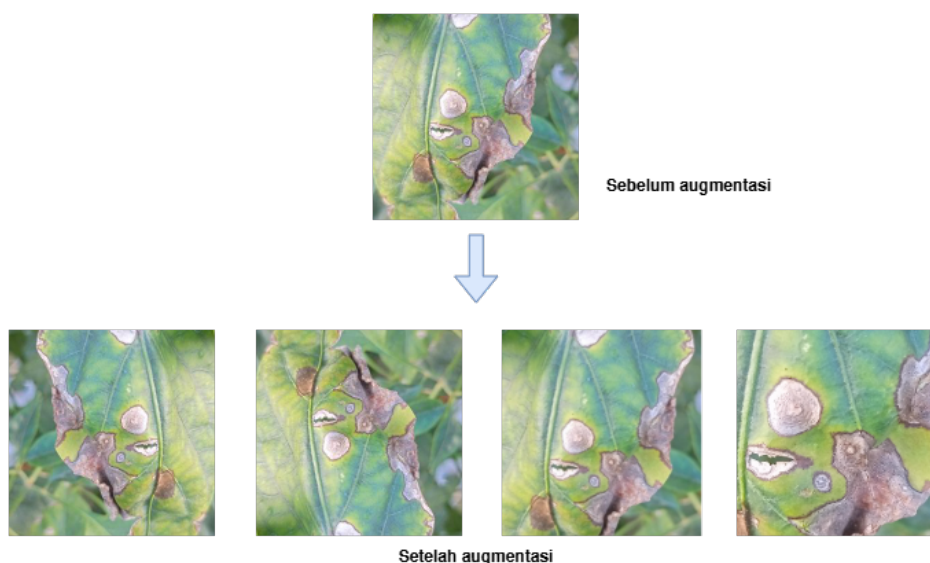
$$recall = \frac{TP}{TP + FN} \quad (3)$$

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

3. HASIL DAN PEMBAHASAN

3.1 Preprocessing Data

Setelah pemodelan dilakukan, data melalui serangkaian proses augmentasi meliputi *resize*, *zoom*, *cropping*, dan *flipping*. Proses ini bertujuan untuk meningkatkan variasi dalam dataset dan membantu model belajar dari berbagai kondisi. Tabel 1 menyajikan perbandingan jumlah citra sebelum dan sesudah proses augmentasi. *Resize* digunakan untuk mengubah ukuran gambar agar sesuai dengan input yang diperlukan oleh model, sementara *flipping* memungkinkan model untuk mengenali objek dari sudut pandang yang berbeda. *Cropping* dan *zoom* membantu dalam menekankan fitur-fitur penting dengan memperbesar bagian tertentu dari gambar. Hasil dari proses augmentasi dapat dilihat pada Gambar 5, yang menunjukkan berbagai transformasi yang diterapkan pada data untuk meningkatkan kinerja model. Pada tahap ini, terdapat kendala yang sering muncul saat melakukan *cropping*, di mana tidak akurat dalam penentuan parameter area *cropping* dapat menyebabkan hasil tidak sesuai dengan area yang diharapkan. Untuk mengatasi hal ini, dilakukan uji coba berulang dengan berbagai pengaturan untuk menemukan parameter *cropping* yang efektif.



Gambar 5 Hasil Preprocessing Data

Tabel 1 Variasi Dataset

No.	Class	Sample	
		Sebelum Augmentasi	Setelah Augmentasi
1	Begomovirus	210	1.050
2	Bercak daun	210	1.050
3	Daun sehat	210	1.050
Total		630	3.150




3.2 Pelatihan Model

Bagian ini menyajikan hasil dan pembahasan penelitian ini, termasuk hasil pelatihan model, evaluasi model, perbandingan model arsitektur MobileNetV2 dan VGG16 dengan menggunakan presisi, recall, dan F1-Score. Sehingga dapat mengevaluasi kelebihan dan kekurangan masing-masing arsitektur dalam konteks pengenalan penyakit pada tanaman. Selain itu, juga dilakukan perbandingan kinerja penelitian ini dengan penelitian lainnya untuk menyoroti keunggulan atau kekurangan model yang digunakan.

3.2.1 MobileNetV2

Akurasi klasifikasi model MobileNetV2 dapat dilihat pada Gambar 6. Dalam penelitian ini, model dilatih selama 15 *epoch*, yang merupakan jumlah iterasi di mana model diperbarui menggunakan data *training*. *Learning rate* yang digunakan adalah 0.0001, yang merupakan parameter penting yang menentukan seberapa besar perubahan bobot model dilakukan di setiap iterasi. *Learning rate* yang kecil ini dirancang untuk membantu menghindari *overfitting* pada minimum fungsi *loss*, memungkinkan model untuk belajar dengan lebih stabil dan mengurangi risiko terjebak pada solusi lokal yang tidak optimal. Optimasi *hyperparameter* dilakukan menggunakan algoritma Adam, yang merupakan salah satu algoritma optimasi paling banyak digunakan dalam *deep learning*.



Gambar 6 Grafik Training MobileNetV2


Grafik yang ditampilkan menunjukkan akurasi *training* sepanjang 15 *epoch*. Pada *epoch* pertama akurasi awal mungkin relatif rendah, namun seiring berjalannya *epoch* akurasi meningkat secara signifikan. Model mencapai akurasi 99,96% pada akhir pelatihan dengan rata-rata waktu komputasi sekitar 222 detik per iterasi. Peningkatan akurasi yang stabil ini menunjukkan bahwa model berhasil belajar dari data *training* dan mampu mengklasifikasikan data dengan baik.

Setelah proses *training* selesai, model diuji menggunakan data *testing* untuk mengevaluasi kinerjanya. Hasil *testing* menunjukkan bahwa model mencapai akurasi sebesar 99,47%, menandakan tingkat keakuratan yang sangat tinggi dalam mendeteksi penyakit pada daun tanaman cabai. Untuk memberikan analisis yang lebih mendalam tentang performa model, evaluasi dilakukan dengan menggunakan *confusion matrix*, seperti yang ditunjukkan pada Gambar 7.

Gambar 7 menunjukkan kinerja model MobileNetV2 dalam mengklasifikasikan penyakit daun tanaman cabai. Secara keseluruhan, model berhasil mengklasifikasikan dengan baik, terutama



kelas begomovirus dan daun sehat. Namun, terdapat kesalahan klasifikasi pada kelas bercak daun yang salah diidentifikasi sebagai daun sehat. *Confusion matrix* yang ditampilkan memberikan rincian lebih lanjut mengenai prediksi model. Tabel 2 menyajikan *classification report* yang memberikan rincian kinerja model dalam mendeteksi penyakit pada daun tanaman cabai, termasuk presisi, recall, F1-score, dan support untuk masing-masing kelas. Secara keseluruhan, tabel ini menunjukkan bahwa model memiliki kinerja yang sangat baik dalam mendeteksi berbagai jenis penyakit pada daun tanaman cabai.



Gambar 7 Confusion Matrix MobileNetV2

Tabel 2 Hasil Testing MobileNetV2

Kelas	Presisi	Recall	F1-Score	Support
Begomovirus	1,00	1,00	1,00	315
Bercak daun	1,00	0,98	0,99	315
Daun sehat	0,98	1,00	0,99	315
Akurasi	-	-	0,99	945
Macro Avg	0,99	0,99	0,99	945
WeightedAvg	0,99	0,99	0,99	945

3.2.2 VGG16


Akurasi klasifikasi model VGG16 ditampilkan pada Gambar 8. Model ini dilatih selama 15 *epoch*, dengan menggunakan *learning rate* yang sama yaitu 0.0001. *Learning rate* ini berfungsi untuk mengatur besarnya perubahan bobot model pada setiap iterasi dan pengaturan ini mirip dengan yang diterapkan pada model MobileNetV2. Tujuan utama dari pengaturan ini adalah untuk mencegah *overfitting* serta memastikan proses pembelajaran yang stabil dan efektif.

Selama *training*, akurasi model menunjukkan peningkatan yang signifikan dari *epoch* pertama hingga akhir *training*. Pada akhir proses *training*, model VGG16 berhasil mencapai akurasi sempurna sebesar 100%. Meskipun hasil ini menunjukkan kemampuan model yang sangat baik dalam mengenali dan mengklasifikasikan data, rata-rata waktu komputasi yang dibutuhkan sekitar 1.092 detik per iterasi sehingga tergolong cukup lama. Meskipun VGG16 menawarkan akurasi yang tinggi, efisiensi waktu yang kurang optimal menjadi salah satu kekurangan yang




perlu dipertimbangkan, terutama dalam skenario yang memerlukan respon cepat. Peningkatan akurasi yang konsisten selama pelatihan menunjukkan bahwa model mampu belajar dengan efektif dari data *training*, meskipun optimasi lebih lanjut masih diperlukan untuk meningkatkan efisiensi komputasi.

Setelah menyelesaikan proses *training*, model diuji menggunakan data *testing* untuk menilai kinerjanya. Hasil evaluasi menunjukkan bahwa model berhasil mencapai akurasi sebesar 98,62%, yang mencerminkan tingkat keakuratan yang sangat baik dalam mendeteksi penyakit pada daun tanaman cabai. Untuk mendapatkan analisis yang lebih mendalam mengenai performa model, evaluasi dilakukan dengan memanfaatkan *confusion matrix*, seperti yang ditunjukkan pada Gambar 9.



Gambar 8 Grafik Training VGG16



Gambar 9 Confusion Matrix VGG16



Gambar 9 menunjukkan kinerja model VGG16 dalam mengklasifikasikan penyakit daun tanaman cabai. Secara keseluruhan, model berhasil mengklasifikasikan dengan baik, terutama kelas begomovirus. Namun, terdapat kesalahan klasifikasi pada kelas bercak daun yang salah diidentifikasi sebagai daun sehat dan kelas daun sehat yang salah diidentifikasi sebagai begomovirus. Tabel 3 menyajikan *classification report* yang mencakup metrik penting seperti presisi, recall, F1-score, dan support untuk setiap kelas penyakit. Secara keseluruhan, hasil yang ditampilkan dalam tabel ini menunjukkan bahwa model memiliki performa yang sangat baik dalam mengidentifikasi berbagai jenis penyakit pada daun tanaman cabai.

Tabel 3 Hasil Testing VGG16

Kelas	Presisi	Recall	F1-Score	Support
Begomovirus	1,00	1,00	1,00	315
Bercak daun	1,00	0,95	0,98	315
Daun sehat	0,95	1,00	0,98	315
Akurasi	-	-	0,98	945
Macro Avg	0,98	0,98	0,98	945
WeightedAvg	0,98	0,98	0,98	945

3.3 Perbandingan Model

Tabel 4 menyajikan perbandingan kinerja antara model MobileNetV2 dan VGG16 dalam hal presisi, recall, dan F1-score. MobileNetV2 menunjukkan kinerja yang efisien dibandingkan dengan model VGG16, di mana menawarkan kecepatan pemrosesan yang jauh lebih baik dan menggunakan ruang yang lebih sedikit. Secara keseluruhan, akurasi tertinggi yang dicapai adalah 99,47% untuk MobileNetV2, sedangkan VGG16 mencapai akurasi sebesar 98,62%. Meskipun kedua model menunjukkan akurasi yang tinggi, waktu komputasi untuk MobileNetV2 jauh lebih efisien dibandingkan dengan VGG16 yang memakan waktu lebih lama dalam proses *training* dan *testing*. Dari hasil ini, dapat disimpulkan bahwa MobileNetV2 tidak hanya unggul dalam hal akurasi, tetapi juga dalam efisiensi, menjadikannya pilihan yang lebih baik untuk klasifikasi penyakit pada daun tanaman cabai. Kelebihan ini menjadikan MobileNetV2 sebagai model yang lebih praktis dan optimal.

Tabel 4 Perbandingan Model MobileNetV2 dan VGG16

Model	Presisi	Recall	F1-Score
MobileNetV2	0,99	0,99	0,99
VGG16	0,98	0,98	0,98

3.4 Perbandingan Kinerja

Tabel 5 menyajikan perbandingan kinerja berbagai model dalam deteksi penyakit tanaman berdasarkan beberapa penelitian terkini. Tabel ini mencakup berbagai dataset, jumlah dataset, jumlah kelas, metode yang digunakan, serta akurasi yang dicapai. Sehingga, memberikan wawasan yang lebih luas mengenai efektivitas model yang diterapkan dalam penelitian ini dibandingkan dengan penelitian lain yang telah dilakukan sebelumnya.

Dalam konteks deteksi penyakit tanaman, penting untuk mempertimbangkan tidak hanya akurasi, tetapi juga kompleksitas model dan waktu komputasi. Hasil yang diperoleh dalam penelitian ini menunjukkan bahwa MobileNetV2 maupun VGG16 dapat mencapai akurasi yang sangat tinggi dalam mendeteksi penyakit pada daun tanaman cabai, dengan MobileNetV2 mencapai 99,47% dan VGG16 mencapai 98,62%. Dibandingkan dengan penelitian (Ramadhani et al., 2023) yang mencapai akurasi 90% dengan dataset yang lebih besar, temuan ini menunjukkan kemajuan signifikan dalam efektivitas model. Penelitian ini menunjukkan bahwa baik MobileNetV2 maupun VGG16 tidak hanya memberikan akurasi yang tinggi, tetapi juga efisiensi yang lebih baik dalam penggunaan sumber daya, menjadikannya pilihan yang lebih praktis untuk aplikasi di lapangan.



Waktu komputasi yang digunakan juga menjadi faktor penting, di mana MobileNetV2 menunjukkan efisiensi yang lebih unggul, seperti pada penelitian (Hermanto et al., 2024) di mana MobileNetV2 lebih efisien dan mengoptimalkan proses *transfer learning* dengan baik. Dengan demikian, perbandingan ini tidak hanya menyoroti keberhasilan model yang diterapkan dalam penelitian ini, tetapi juga memberikan konteks yang lebih luas tentang kemajuan dalam deteksi penyakit tanaman, serta potensi untuk pengembangan lebih lanjut dalam teknologi pertanian berbasis kecerdasan buatan.

Tabel 5 Perbandingan Kinerja Deteksi

Referensi	Dataset	Jumlah Dataset	Kelas	Metode	Akurasi (%)
Ramadhani et al. (2023)	Penyakit daun cabai	5.000	5	MobileNetV2	90
Pramudhita et al. (2023)	Penyakit daun strawberry	1.336	4	MobileNetV3-Large	92,14
D. Li et al. (2024)	Penyakit daun cabai	2.500	5	MCCM CNN	93,5
Raghuram & Borah (2025)	Penyakit daun tomat	14.000	8	DRL-TL	99,23
Arnob et al. (2025)	Penyakit daun kembang kol	7.360	4	Custom CNN, InceptionV3, ResNet50, VGG16	83,94 76,53 90,85 65,58
Chaithanya & Rachana (2023)	Penyakit daun pepaya	2.159	5	CNN, VGG16, VGG19, Inception V3, DenseNet 121, MobileNet V2, EfficientNet B0, ResNet50	72,76 84,82 83,48 73,67 86,16 83,93 86,61 87,95
Raufer et al. (2025)	Penyakit daun timun	1.289	8	VGG19	93,87
Penelitian ini	Penyakit daun cabai	3.150	3	MobileNetV2 dan VGG16	99,47 dan 98,62

4. KESIMPULAN

Penelitian ini berhasil melatih dua model, yaitu MobileNetV2 dan VGG16, untuk mendeteksi penyakit pada daun tanaman cabai. MobileNetV2 mencapai akurasi 99,47%, sedangkan VGG16 mencapai akurasi 98,62%. Kedua model menunjukkan kemampuan yang sangat baik dalam klasifikasi, namun MobileNetV2 unggul dalam efisiensi waktu komputasi. Temuan ini memberikan kontribusi positif terhadap pengembangan teknologi pertanian berbasis kecerdasan buatan, menunjukkan potensi besar dalam penggunaan model *transfer learning* untuk deteksi penyakit tanaman secara efektif dan efisien. Disarankan supaya penelitian selanjutnya dapat mengeksplorasi penggunaan model lain yang lebih canggih dan melakukan optimasi lebih lanjut pada *hyperparameter* untuk meningkatkan efisiensi dan akurasi.

DAFTAR PUSTAKA

Alkanan, M., & Gulzar, Y. (2024). Enhanced Corn Seed Disease Classification: Leveraging MobileNetV2 with Feature Augmentation and Transfer Learning. *Frontiers in Applied Mathematics and Statistics*, 9(1), Article ID:1320177. <https://doi.org/10.3389/fams.2023.1320177>

Andini, W., Zahra, S. K., Abdurrahman, M., & Sebayang, V. B. (2024). Analisis Fluktuasi Harga Terhadap Faktor-Faktor yang Mempengaruhi Produktivitas Usaha Tani Cabai Merah di



- Indonesia. *Jurnal Riset dan Inovasi Manajemen*, 2(2), 162–172. <https://doi.org/10.59581/jrim-widyakarya.v2i2.3526>
- Arnob, A. S., Kausik, A. K., Islam, Z., Khan, R., & Bin Rashid, A. (2025). Comparative Result Analysis of Cauliflower Disease Classification Based on Deep Learning Approach VGG16, Inception V3, ResNet, and a Custom CNN Model. *Hybrid Advances*, 10, Article ID: 100440. <https://doi.org/10.1016/j.hybadv.2025.100440>
- Chaithanya, A. S., & Rachana, M. (2023). Identification of Diseased Papaya Leaf Through Transfer Learning. *Indian Journal of Science and Technology*, 16(48), 4676–4687. <https://doi.org/10.17485/IJST/v16i48.2690>
- Gulzar, Y. (2023). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability*, 15(3), Article ID: 1906. <https://doi.org/10.3390/su15031906>
- Hermanto, A. R., Aziz, A., & Sudianto, S. (2024). Perbandingan Arsitektur MobileNetV2 dan ResNet50 untuk Klasifikasi Jenis Buah Kurma. *Jurnal Sistem dan Teknologi Informasi (JustIN)*, 12(4), 630–637. <https://doi.org/10.26418/justin.v12i4.80358>
- Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On Evaluation Metrics for Medical Applications of Artificial Intelligence. *Scientific Reports*, 12(1), Article ID: 5979. <https://doi.org/10.1038/s41598-022-09954-8>
- Li, D., Zhang, C., Li, J., Li, M., Huang, M., & Tang, Y. (2024). MCCM: Multi-Scale Feature Extraction Network for Disease Classification and Recognition of Chili Leaves. *Frontiers in Plant Science*, 15, 1–19. <https://doi.org/10.3389/fpls.2024.1367738>
- Li, Y., Zou, D., Shrestha, N., Xu, X., Wang, Q., Jia, W., & Wang, Z. (2020). Spatiotemporal Variation in Leaf Size and Shape in Response to Climate. *Journal of Plant Ecology*, 13(1), 87–96. <https://doi.org/10.1093/jpe/rtz053>
- Maftukhah, A., Fadlil, A., & Sunardi, S. (2024). Butterfly Image Classification Using Convolution Neural Network with AlexNet Architecture. *Jurnal INFOTEL*, 16(1), 82–95. <https://doi.org/10.20895/infotel.v16i1.1004>
- Mostafa, S., Wang, Y., Zeng, W., & Jin, B. (2022). Plant Responses to Herbivory, Wounding, and Infection. *International Journal of Molecular Sciences*, 23(13), Article ID: 7031. <https://doi.org/10.3390/ijms23137031>
- Muis, A., Sunardi, S., & Yudhana, A. (2024). CNN-based Approach for Enhancing Brain Tumor Image Classification Accuracy. *International Journal of Engineering*, 37(5), 984–996. <https://doi.org/10.5829/IJE.2024.37.05B.15>
- Nguyen, T.-H., Nguyen, T.-N., & Ngo, B.-V. (2022). A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease. *AgriEngineering*, 4(4), 871–887. <https://doi.org/10.3390/agriengineering4040056>
- Paymode, A. S., & Malode, V. B. (2022). Transfer Learning for Multi-Crop Leaf Disease Image Classification Using Convolutional Neural Network VGG. *Artificial Intelligence in Agriculture*, 6(1), 23–33. <https://doi.org/10.1016/j.aiia.2021.12.002>
- Pramudhita, D. A., Azzahra, F., Arfat, I. K., Magdalena, R., & Saidah, S. (2023). Strawberry Plant Diseases Classification Using CNN Based on MobileNetV3-Large and EfficientNet-B0 Architecture. *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, 9(3), 522–534. <https://doi.org/10.26555/jiteki.v9i3.26341>
- Prasetyo, A. D., & Agustinur, A. (2023). Inventarisasi Penyakit pada Tanaman Cabai Merah (*Capsicum annum* L.) di Kebun Warga Gampong Suak Raya Kecamatan Johan Pahlawan Kabupaten Aceh Barat. *Jurnal Agrotek Lestari*, 8(1), 70–75. <https://doi.org/10.35308/jal.v8i1.5293>
- Prasetyo, K., Putri, D. D., Kartika Eka Wijayanti, I., & Zulkifli, L. (2023). Forecasting of Red Chilli Prices in Banyumas Regency: The ARIMA Approach. *E3S Web of Conferences*, 444, Article ID: 02017. <https://doi.org/10.1051/e3sconf/202344402017>
- Raghuram, K., & Borah, M. D. (2025). A Hybrid Learning Model for Tomato Plant Disease Detection Using Deep Reinforcement Learning with Transfer Learning. *Procedia Computer Science*, 252, 341–354. <https://doi.org/10.1016/j.procs.2024.12.036>
- Ramadhani, A. N. M., Saraswati, G. W., Agung, R. T., & Santoso, H. A. (2023). Performance Comparison of Convolutional Neural Network and MobileNetV2 for Chili Diseases



- Classification. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(4), 940–946. <https://doi.org/10.29207/resti.v7i4.5028>
- Raufer, L., Wiedey, J., Mueller, M., Penava, P., & Buettner, R. (2025). A Deep Learning-Based Approach for the Detection of Cucumber Diseases. *PLOS ONE*, 20(4), Article ID: e0320764. <https://doi.org/10.1371/journal.pone.0320764>
- Rustanto, D. W., Liantoni, F., & Prakisy, N. P. T. (2024). Identifikasi Penyakit Daun pada Tanaman Padi Menggunakan Ekstraksi Fitur Gray Level Co-occurrence Matrix (GLCM) dan Metode K-Nearest Neighbour (KNN). *Jurnal Sistem dan Teknologi Informasi (JustIN)*, 12(1), 100–106. <https://doi.org/10.26418/justin.v12i1.69752>
- Sekretariat Jenderal Kementerian Pertanian. (2023). *Statistik Konsumsi Pangan Tahun 2023* (Mas'ud & S. Wahyuningsih, Eds.). Pusat Data dan Sistem Informasi Pertanian.
- Siddiqui, F. M. (2023). Chili Leaf Disease Prediction Using CNN. *International Journal for Research in Applied Science and Engineering Technology*, 11(5), 4791–4797. <https://doi.org/10.22214/ijraset.2023.52757>
- Singh, T., Kumar, K., & Bedi, S. (2021). A Review on Artificial Intelligence Techniques for Disease Recognition in Plants. *IOP Conference Series: Materials Science and Engineering*, 1022(1), Article ID: 012032. <https://doi.org/10.1088/1757-899X/1022/1/012032>
- Syukur, M. (2018). *8 Kiat Sukses Panen Cabai Sepanjang Musim*. AgroMedia Pustaka.
- Winiarti, S., & Khoirunnisa, I. I. (2024). Mobile Application Development for Chili Disease Detection with Convolutional Neural Network. *International Journal of Informatics and Computation*, 6(2), 97–112. <https://doi.org/10.35842/ijicom.v6i2.93>

