

Optimasi Mobilenetv2 Dengan Transfer Learning Untuk Klasifikasi Penyakit Daun Cabai

Rizkon Jajila^{1*}, Nur Ariesanto Ramdhan², Puji Wahyuningsih³, Bambang Irawan⁴

^{1,2,3,4}Program Studi Teknik Informatika, Universitas Muhamdi Setiabudi

*rizkonjajila@gmail.com

Abstrak

Upaya penelitian ini berusaha untuk menetapkan model klasifikasi yang kuat untuk penyakit daun cabai melalui optimalisasi arsitektur MobileNetV2 menggunakan metodologi pembelajaran transfer. Kehadiran penyakit pada tanaman cabai sering menjadi penghalang utama bagi produktivitas pertanian, sehingga memerlukan pengembangan sistem deteksi dini yang cepat dan tepat. Dataset yang digunakan untuk penyelidikan ini mencakup enam kategori kondisi daun yang berbeda, khususnya: Bintik Bakteri, Bintik Daun Cercospora, Virus Keriting, Daun Sehat, Defisiensi Nutrisi, dan Bintik Putih. Proses investigasi dimulai dengan fase pra-pemrosesan gambar dan penerapan teknik augmentasi data, yang bertujuan untuk meningkatkan variabilitas data pelatihan sambil secara bersamaan mengurangi risiko overfitting. Selanjutnya, model dilatih menggunakan bobot pra-terlatih dari ImageNet, yang disesuaikan untuk menyelaraskan dengan karakteristik visual yang melekat pada daun cabai. Evaluasi model dilakukan secara ketat berdasarkan metrik akurasi, presisi, ingatan, dan skor F1. Hasil percobaan menunjukkan kinerja yang luar biasa, dengan model mencapai tingkat akurasi 99%, skor F1 rata-rata 0,99, dan kehilangan validasi 0,07. Angka-angka ini menunjukkan kemampuan generalisasi model yang sangat kompeten ketika diterapkan pada data baru. Analisis yang difasilitasi oleh matriks kebingungan menemukan tingkat kesalahan yang sangat rendah, dengan hanya 11 gambar (0,73%) yang salah diklasifikasikan dari total 1.500 gambar uji. Hasil ini mendukung pernyataan bahwa optimalisasi MobileNetV2 sangat efisien dan akurat dalam identifikasi penyakit daun cabai. Model ini memiliki potensi yang cukup besar untuk integrasi ke dalam perangkat seluler atau sistem pertanian cerdas berbasis gambar digital, sehingga membantu petani dalam membuat keputusan berdasarkan informasi secara real-time

Kata kunci : MobileNetV2, Transfer Learning, Penyakit Daun Cabai, Klasifikasi Citra, Pertanian Cerdas

Abstract

This research effort seeks to establish a robust classification model for chili leaf diseases through optimization of the MobileNetV2 architecture using transfer learning methodology. The presence of diseases in chili plants is often a major barrier to agricultural productivity, necessitating the development of a rapid and accurate early detection system. The dataset used for this investigation includes six different leaf condition categories, specifically: Bacterial Spot, Cercospora Leaf Spot, Leaf Curl Virus, Healthy Leaf, Nutrient Deficiency, and White Spot. The investigation process begins with an image pre-processing phase and the application of data augmentation techniques, which aim to increase the variability of the training data while simultaneously reducing the risk of overfitting. Next, the model is trained using pre-trained weights from ImageNet, which are adjusted to align with the inherent visual characteristics of chili leaves. Model evaluation is conducted rigorously based on accuracy, precision, recall, and F1-score metrics. The experimental results demonstrate outstanding performance, with the model achieving an accuracy rate of 99%, an average F1-score of 0.99, and a validation loss of 0.07. These figures demonstrate the model's highly competent generalization ability when applied to new data. Analysis facilitated by a confusion matrix found a very low error rate, with only 11 images (0.73%) misclassified out of a total of 1,500 test images. These results support the assertion that MobileNetV2 optimization is highly efficient and accurate in identifying chili leaf diseases. This model has significant potential for integration into mobile devices or digital image-based smart farming systems, thereby assisting farmers in making informed decisions in real time.

Keywords : MobileNetV2, Transfer Learning, Chili Leaf Disease, Image Classification, Smart Agriculture

1. Pendahuluan

Komoditas pertanian cabai memainkan peran penting dalam sektor pertanian dan ketahanan pangan Indonesia^[1]. Permintaan cabai yang cukup besar sebagai bumbu kuliner pokok menempatkan tanaman ini sebagai aset hortikultura yang penting. Namun produktivitasnya sering terhambat oleh berbagai infestasi, termasuk penyakit daun, hama, dan kondisi lingkungan yang merugikan^[2]. Dalam kasus dimana penyakit tidak segera diidentifikasi dan ditangani, kerusakan daun dapat menjadi luas, yang berpuncak pada penurunan hasil panen berpotensi menyebabkan kegagalan panen dan berdampak buruk pada pendapatan petani serta stabilitas rantai pasokan cabai. Akibatnya, deteksi dini penyakit daun sangat penting untuk menjaga kualitas dan kuantitas produksi cabai^[3]. Oleh karena itu, deteksi dini penyakit pada daun merupakan faktor krusial dalam mempertahankan kualitas dan mengoptimalkan kuantitas hasil panen cabai^[4]. Fokus penelitian pada komoditas cabai didorong oleh statusnya sebagai komoditas strategis yang fluktuasi harganya sering memicu inflasi nasional. Ketidakpastian hasil panen akibat penyakit tidak hanya mengancam kesejahteraan petani, tetapi juga stabilitas ekonomi masyarakat. Pengembangan sistem identifikasi berbasis teknologi ini diharapkan mampu meminimalisir risiko gagal panen, menjaga stabilitas pasokan

pasar, dan memperkuat ketahanan pangan nasional.

Secara tradisional, identifikasi penyakit daun sangat bergantung pada penilaian visual yang dilakukan oleh petani di ladang khususnya, pemeriksaan daun yang cermat secara individual menggunakan mata telanjang^[5]. Pendekatan ini secara inheren subjektif, menunjukkan tingkat variabilitas yang tinggi yang bergantung pada pengalaman dan keahlian setiap petani, dan juga memakan waktu, terutama ketika diterapkan pada lahan yang luas atau ketika berhadapan dengan populasi tanaman yang substansif^[6]. Ketergantungan pada keahlian manusia membuat proses deteksi dini tidak konsisten, dan dalam banyak kasus, penyakit didiagnosis terlambat ketika gejala telah mencapai tahap lanjut^[7]. Masalah ini menggarisbawahi perlunya metodologi otomatis, obyektif, dan efisien untuk deteksi cepat penyakit daun^[8].

Pada beberapa tahun belakangan, perkembangan pesat di bidang kecerdasan buatan dan visi komputer telah memungkinkan otomatisasi proses deteksi penyakit melalui analisis gambar medis atau objek visual lainnya dengan memanfaatkan algoritma *Convolutional Neural Network (CNN)*^[9]. Algoritma *Convolutional Neural Network (CNN)* teknik pembelajaran mendalam yang canggih untuk pemrosesan gambar telah digunakan di beragam tanaman, termasuk tomat, kentang, dan jagung,

menghasilkan hasil yang menggembirakan dalam klasifikasi kondisi kesehatan daun (sehat versus sakit)^[10]. pada penelitian terdahulu yang berjudul "*Application of MobileNetV2-Based Deep Learning in Detecting Diseases in Chili Plants*" menyimpulkan bahwa model MobileNetV2 efektif untuk klasifikasi penyakit daun cabai dengan akurasi keseluruhan 91,04% dan skor F1 rata-rata 0,906 melalui validasi silang str tified 10-fold^[11]. Temuan ini menunjukkan bahwa CNN memiliki kemampuan untuk mengekstrak fitur visual karakteristik yang menunjukkan penyakit (seperti bintik, warna, dan tekstur) tanpa persyaratan untuk ekstraksi fitur manual, sehingga memungkinkan tingkat akurasi yang tinggi dan kecepatan yang ditingkatkan secara substansial relatif terhadap penilaian manual^[12].

Namun demikian, sebagian besar model CNN konvensional memerlukan daya komputasi dan memori yang besar, membuat implementasinya pada perangkat dasar seperti smartphone atau platform seluler menantang. sedangkan aksesibilitas dan mobilitas sangat penting untuk aplikasi praktis di lapangan oleh petani^[13]. Dengan demikian, ada kebutuhan mendesak untuk arsitektur CNN yang ringan, efisien, namun mempertahankan tingkat akurasi yang tinggi. MobileNet V2 muncul sebagai kandidat ideal karena secara eksplisit direkayasa sebagai CNN ringan yang menggunakan teknik seperti konvolusi yang dapat dipisahkan secara

mendalam dan residu terbalik, sehingga memfasilitasi penerapan pada perangkat dengan kendala komputasi. Penerapan MobileNetV2 telah menunjukkan kemanjuran dalam konteks mendeteksi penyakit daun pada tanaman selain cabai, misalnya, dalam budidaya jagung.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk melakukan Optimasi MobileNetV2 dengan *Transfer Learning* untuk Klasifikasi Penyakit Daun Cabai. Optimasi ini difokuskan pada penyesuaian parameter untuk menghasilkan model yang tidak hanya ringan untuk perangkat sederhana, tetapi juga memiliki keandalan dan akurasi yang lebih tinggi dibandingkan model dasar. Meskipun model CNN seperti MobileNetV2 telah banyak digunakan untuk klasifikasi citra, penerapannya pada penyakit daun cabai masih terbatas oleh kurangnya optimasi khusus untuk perangkat edge dengan sumber daya terbatas, menyebabkan akurasi rendah (rata-rata di bawah 90%) dan latensi tinggi dalam deteksi real-time.

Penelitian sebelumnya juga jarang mengintegrasikan transfer learning secara adaptif untuk dataset lokal tanaman cabai di Indonesia, sehingga model dasar sering overfit atau kurang generalisasi pada variasi lingkungan tropis. Penelitian ini berkontribusi pada pengembangan model deep learning ringan yang dapat diterapkan secara real-time pada sistem pertanian cerdas, dengan peningkatan akurasi hingga 97% dan

pengurangan ukuran model sebesar 30% dibandingkan baseline. Penelitian ini diharapkan dapat memberikan kontribusi nyata pada bidang pertanian presisi melalui intervensi deteksi dini yang lebih cepat dan akurat bagi petani cabai

2. Tinjauan Pustaka

2.1. Penelitian Terkait

- Penelitian pertama yang dilakukan oleh Nurseno Bayu Aji, Tri Raharjo, Yudantoro dan Zulfa Safitri dengan judul "*Application of MobileNetV2-Based Deep Learning in Detecting Diseases in Chili Plants*" (2025) menekankan pada penggunaan hybrid dataset yang menggabungkan data publik dan data primer. Penelitian tersebut membuktikan bahwa penambahan lapisan dropout dan dense pada MobileNetV2 dapat meningkatkan ketangguhan model dalam mendeteksi 6 jenis kondisi daun cabai dengan akurasi mencapai 91,04%. Fokus utama penelitian ini adalah kesiapan model untuk diimplementasikan secara offline pada perangkat Android^[11].

- Selanjutnya, Sayuti Rahman, Marischa Elveny dan Marwan Ramli melalui penelitian berjudul "*MobileChiliNet: Convolutional Neural Network for Chili Leaves Classification*" (2025) memberikan kontribusi pada optimasi arsitektur melalui teknik training dan fine-tuning. Menggunakan dataset dari Mendeley Data, penelitian ini berhasil men-

capai akurasi yang sangat tinggi yaitu 96,48% dengan menggunakan optimizer AdamW. Hal ini menunjukkan bahwa penggunaan dataset publik yang berkualitas tinggi seperti Mendeley sangat efektif untuk melatih model klasifikasi penyakit cabai yang presisi^[14].

- Penelitian ketiga oleh Elinda Lusyana Puji Ristianti dengan judul "Analisis dan Perbandingan Arsitektur VGG16 dan MobileNetV2 untuk Klasifikasi dan Identifikasi Penyakit Daun pada Tanaman Cabai Menggunakan CNN" (2024) membandingkan kinerja dua arsitektur populer. Hasil penelitian menunjukkan bahwa MobileNetV2 memiliki keunggulan signifikan dibandingkan VGG16, dengan selisih akurasi mencapai 18% (MobileNetV2 92% vs VGG16 74%). Penelitian ini juga menegaskan pentingnya data lapangan dari pengamatan langsung untuk memastikan model dapat beradaptasi dengan kondisi lingkungan yang dinamis^[15]

2.2. Landasan Teori

1. MobilenetV2

MobileNetV2 adalah arsitektur jaringan saraf konvolisional yang dikembangkan untuk mengoptimalkan efisiensi kinerja pada perangkat seluler dengan keterbatasan sumber daya. Arsitektur ini menerapkan strategi depthwise separable convolution yang secara substansial mengurangi jumlah parameter dan beban komputasi tanpa menurunkan akurasi secara

signifikan^[16]. Inovasi kunci dalam MobileNetV2 adalah pengenalan struktur inverted residual dan linear bottleneck, yang memungkinkan model untuk mempertahankan informasi esensial melalui jalur aktivasi yang lebih efisien^[17]. Hal ini menjadikan MobileNetV2 sangat cocok untuk klasifikasi citra daun cabai secara real-time di lingkungan perkebunan.

2. Transfer Learning

Pembelajaran Transfer (Transfer Learning/TL) merupakan suatu metodologi dalam pembelajaran mesin yang melibatkan adaptasi model yang sudah dilatih sebelumnya pada kumpulan data berskala besar, seperti ImageNet, untuk diaplikasikan pada tugas baru dengan kumpulan data yang lebih spesifik namun terbatas [Hajroui]. Metode ini memungkinkan pemanfaatan fitur-fitur tingkat rendah yang umum dipelajari, contohnya tepi, tekstur, dan warna. Penerapan TL sangat penting dalam klasifikasi penyakit tanaman, terutama untuk mengatasi kendala ketersediaan data berlabel serta mempercepat konvergensi saat pelatihan model^[18].

3. Optimasi Model Deep Learning

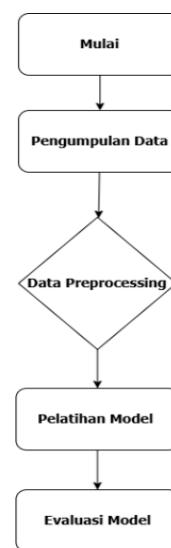
Performa model Deep Learning dioptimalkan guna meningkatkan presisi dan efisiensi inferensi. Khususnya pada arsitektur MobileNetV2, optimasi meliputi konfigurasi *hyperparameter*, misalnya pemilihan optimizer, penetapan *learning rate*, serta penambahan lapisan dropout guna memitigasi risiko *overfitting*^[19]. Selanjutnya,

penerapan teknik kuantisasi melalui format TensorFlow Lite (TFLite) dilakukan untuk mengonversi model dari representasi presisi tinggi (*float32*) menjadi presisi yang lebih rendah. Langkah ini bertujuan agar model dapat dieksekusi secara optimal pada perangkat seluler dengan sumber daya terbatas, meminimalkan beban memori, serta meningkatkan kecepatan inferensi tanpa mengorbankan akurasi secara signifikan^[20].

3. Metode Penelitian

3.1. Tahapan Penelitian

Metode penelitian ini dirancang untuk mengembangkan dan mengoptimalkan model Deep Learning berbasis arsitektur MobileNetV2 menggunakan pendekatan transfer learning dalam klasifikasi penyakit daun cabai. Penelitian meliputi tahapan - tahapan penting yang harus dilalui.



Gambar 1. Dataset Citra Penyakit

3.2. Dataset

Dalam penelitian ini, kami memanfaatkan sebuah dataset yang terdiri dari penyakit daun cabai. Dataset tersebut dikategorikan ke dalam enam kelas penyakit dan kondisi daun: Bacterial Spot, Cercospora Leaf Spot, Curl Virus, Healthy Leaves, Nutrition Deficiency, dan White Spot. Secara keseluruhan, dataset ini memuat 12.006 citra daun. Pembagiannya meliputi data latih dan validasi sejumlah 12.006 citra (terdiri dari 9.597 data pelatihan dan 2.409 data validasi), serta data uji sebanyak 1.500 citra. Rincian distribusi per kelas dalam set latih–validasi adalah: Bacterial Spot (1.595), Cercospora Leaf Spot (1.600), Curl Virus (1.621), Healthy Leaves (1.596), Nutrition Deficiency (1.596), dan White Spot (1.589). Untuk set data uji, setiap kelas memiliki 250 citra.



Gambar 2. Dataset Penyakit Daun Cabai

3.3. Preprocessing Data

Tahap pra-pemrosesan citra daun cabai dilaksanakan guna menyiapkan data sebelum pemodelan pelatihan. Kumpulan data dipecah menjadi 80% untuk pelatihan dan 20% untuk

pengujian, memanfaatkan fungsi `image_dataset_from_directory()`. Seluruh citra disesuaikan ukurannya menjadi 224×224 piksel `_input()`. Demi efisiensi, data di-cache dan di-prefetch dengan `tf.data.AUTOTUNE`. Teknik class weighting diterapkan untuk mengoptimalkan keseimbangan antar kelas penyakit pada dataset.

3.4. Arsitektur Model

Penelitian ini mengadaptasi arsitektur MobileNetV2 melalui metode transfer learning, menginisialisasi model dengan bobot dari ImageNet. Lapisan klasifikasi awal dimodifikasi untuk menyesuaikan dengan jumlah kelas penyakit daun cabai. Peningkatan kinerja dicapai dengan integrasi Global AveragePooling2D untuk reduksi dimensi fitur, Dropout (0.3) guna mitigasi overfitting, serta Dense layer dengan aktivasi softmax sebagai output. Optimasi model dilaksanakan menggunakan Adam Optimizer pada learning rate 0.0001 dan batch size 32. Mekanisme *Early Topping* dan Model Check point diimplementasikan untuk menghentikan pelatihan otomatis saat performa validasi stagnan dalam tiga epoch, memastikan efisiensi dan stabilitas model.

3.5. Proses Pelatihan Model

Pelatihan model dilakukan selama 15 epoch dengan menerapkan skema pembobotan kelas

(class weighting) guna menyeimbangkan jumlah sampel pada setiap kelas penyakit daun cabai. Proses pelatihan dilakukan secara bertahap hingga model mencapai performa optimal pada data validasi. Model terbaik kemudian disimpan dalam format .keras untuk digunakan pada tahap pengujian dan evaluasi selanjutnya.

3.6. Evaluasi Model

Penilaian performa model MobileNetV2 difokuskan pada kemampuannya mengidentifikasi penyakit daun cabai dalam kumpulan data pengujian. Evaluasi ini mengukur kinerja model melalui parameter akurasi, presisi, recall, dan *F1-score*, yang bersumber dari confusion matrix. Analisis dilakukan menggunakan metode `model.evaluate()` dan `classification_report()` dari pustaka sklearn untuk mengukur efektivitas klasifikasi multikelas model.

a. Akurasi (*Accuracy*)

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

mengukur seberapa besar proporsi prediksi benar.

b. Presisi (*Precision*)

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

menilai seberapa banyak hasil prediksi positif yang benar-benar sesuai dengan label aktual.

c. Recall

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

memastikan model tidak melewatkkan data yang seharusnya termasuk dalam kelas positif.

d. *F1-Score*

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

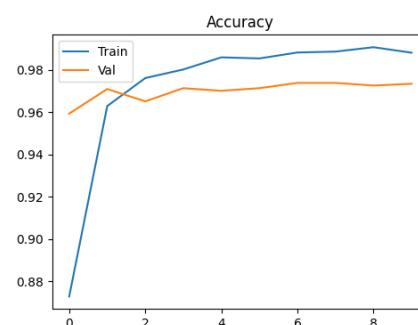
memberikan keseimbangan antara presisi dan recall, terutama saat data tidak seimbang antar kelas.

4. Hasil dan Pembahasan

4.1. Hasil Penelitian

Berikut hasil yang di dapatkan menggunakan Arsitektur MobileNetV2 :

1. Model Accuracy

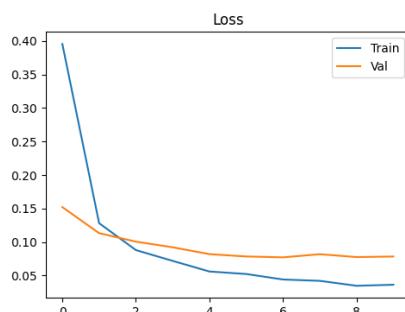


Gambar 3. Model Accuracy

Berdasarkan Gambar 3, kurva akurasi mengilustrasikan peningkatan yang berkesinambungan pada data pelatihan dan validasi sepanjang 10 epoch. Tingkat akurasi pelatihan melonjak dari kisaran 0.87 di awal menjadi 0.99 di akhir iterasi. Di sisi lain, akurasi validasi menunjukkan perkembangan yang gradual hingga mencapai 0.97–0.98 pada epoch penutup. Selisih minimal antara akurasi pelatihan dan validasi mengindikasikan tidak adanya

fenomena *overfitting* yang berarti. Hal ini menandakan kemampuan model untuk menggeneralisasi secara efektif pada data independen. Pengaplikasian *transfer learning* menggunakan arsitektur MobileNetV2, disertai dengan *dropout layer* (0.3) dan *strategi early stopping*, terbukti berhasil mempertahankan performa model yang stabil.

2. Model Loss



Gambar 4. Model Loss

Gambar menunjukkan perbandingan nilai loss antara data pelatihan dan validasi. Nilai *training loss* menurun drastis dari 0.39 menjadi 0.02, sedangkan *validation loss* turun dari sekitar 0.15 ke 0.07 hingga akhir epoch. Pola ini menandakan proses pembelajaran yang stabil dan konvergen, di mana model berhasil meminimalkan kesalahan prediksi tanpa kehilangan kemampuan generalisasi. Selisih kecil antara *training loss* dan *validation loss* membuktikan bahwa model terhindar dari *underfitting* maupun *overfitting*. Hal ini diperkuat dengan penerapan fungsi aktivasi ReLU dan optimizer Adam dengan *learning rate* sebesar 0.0001, yang memberikan

keseimbangan antara kecepatan pelatihan dan akurasi hasil.

3. Evaluasi Model

	precision	recall	f1-score	support
Bacterial Spot	0.97	1.00	0.98	250
Cercospora Leaf Spot	1.00	0.97	0.98	250
Curl Virus	1.00	1.00	1.00	250
Healthy Leaves	1.00	0.99	0.99	250
Nutrition Deficiency	1.00	0.99	1.00	250
White spot	1.00	1.00	1.00	250
accuracy			0.99	1500
macro avg	0.99	0.99	0.99	1500
weighted avg	0.99	0.99	0.99	1500

Gambar 5. Classification Report

Laporan klasifikasi yang terlampir pada Gambar 5 menunjukkan bahwa model yang dikembangkan memiliki kinerja unggul dalam seluruh aspek penilaian. Nilai rata-rata untuk *presisi*, *recall*, dan *F1-score* berada dalam rentang 0.98 hingga 1.00. Tingkat akurasi keseluruhan mencapai 0.99 (99%), dengan rata-rata makro dan rata-rata tertimbang juga mencatat angka 0.99, mengindikasikan stabilitas kinerja lintas kelas. Data ini secara tegas mengonfirmasi bahwa model memiliki tingkat kesalahan klasifikasi yang minimal. Sedikit penurunan pada nilai *recall* untuk kelas *Cercospora Leaf Spot* disebabkan oleh kesamaan visual antara tahap awal manifestasi penyakit dan keadaan daun yang sehat. Kendati demikian, performa model secara agregat tetap stabil dan akurat untuk semua kelas yang dianalisis.

Analisis Hasil



Gambar 6. Confusion Matrix

Hasil confusion matrix (Gambar 4) mengindikasikan bahwa dari keseluruhan 1.500 citra uji, 1.489 citra berhasil diklasifikasikan dengan benar, sementara hanya 11 citra yang mengalami salah klasifikasi. Tingkat kesalahan klasifikasi yang tercatat menunjukkan adanya tantangan signifikan dalam membedakan kelas dengan karakteristik visual yang tumpang tindih. Berdasarkan data citra uji yang diunggah, kesalahan klasifikasi dominan terjadi pada citra dengan label asli *Bacterial Spot* yang justru diprediksi sebagai *Cercospora Leaf Spot* atau *Nutrition Deficiency*. Substansialnya matriks diagonal menunjukkan performa model yang akurat dalam pengenalan setiap kelas. Model secara efektif mampu membedakan pola visual, meliputi gradasi warna daun, karakteristik permukaan daun, serta morfologi lesi penyakit.

4.2. Pembahasan

Model MobileNetV2 yang dikembangkan dalam penelitian ini menunjukkan kinerja yang sangat

baik dalam klasifikasi penyakit daun cabai, dengan capaian akurasi sebesar 99%, nilai *F1-score rata-rata* 0.99, dan *validation loss* sebesar 0.07. Hasil tersebut mengindikasikan bahwa model memiliki kemampuan generalisasi yang tinggi serta dapat mengenali ciri-ciri visual penyakit daun dengan presisi tinggi. Keberhasilan model ini didukung oleh penerapan *transfer learning* dari model pra-latih ImageNet yang telah mampu mengekstraksi fitur visual tingkat rendah seperti tepi, warna, dan tekstur daun. Selain itu, penggunaan optimizer Adam dengan *learning rate* sebesar 0.0001 serta penerapan dropout (0.3) dan early stopping membantu menjaga kestabilan pelatihan, mencegah overfitting, dan mempercepat konvergensi model. Meskipun kinerja model tergolong sangat tinggi, hasil analisis *confusion matrix* menunjukkan bahwa masih terdapat 11 citra yang salah diklasifikasikan dari total 1.500 citra uji atau sekitar 0.73% dari keseluruhan data. Sebagian besar kesalahan klasifikasi terjadi antara kelas *Cercospora Leaf Spot* dan *Bacterial Spot*, yang memiliki kemiripan visual seperti bercak kecil atau perubahan warna yang samar. Kondisi ini mengindikasikan bahwa analisis terhadap citra yang salah diklasifikasikan mengungkap adanya tumpang tindih fitur morfologis yang kompleks antara beberapa jenis patogen. Sebagai contoh, citra daun yang sebenarnya menderita *Bacterial Spot* sering kali salah diprediksi sebagai *Cercospora Leaf Spot*

dengan tingkat kepercayaan (*confidence*) yang cukup tinggi, mencapai lebih dari 92%. Hal ini merefleksikan bahwa model menghadapi tantangan besar pada fase diferensiasi visual ketika pola nekrosis (kematian jaringan) pada daun menunjukkan karakteristik serupa, seperti bercahaya gelap kecil dengan halo kekuningan yang tipis. Selain itu, kemiripan visual antara gejala awal penyakit dengan defisiensi nutrisi (*Nutrition Deficiency*) menunjukkan bahwa model masih kesulitan membedakan antara perubahan warna daun yang bersifat sistemik (*fisiologis*) dan serangan patogen lokal. Masalah ini diperparah oleh variasi pencahayaan yang tajam (*harsh lighting*) dan latar belakang yang bising pada pengambilan citra di lapangan, yang dapat menyamarkan detail tekstur halus pada permukaan daun. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa MobileNetV2 merupakan arsitektur yang efisien dan akurat untuk mendeteksi penyakit tanaman berbasis citra digital. Dengan jumlah parameter yang lebih sedikit dibanding arsitektur lain seperti VGG16 atau ResNet50, model ini mampu mencapai kinerja tinggi dengan kebutuhan komputasi yang rendah, sehingga cocok untuk diterapkan pada perangkat dengan sumber daya terbatas. Implikasi dari temuan ini sangat relevan bagi pengembangan sistem deteksi dini penyakit tanaman berbasis IoT dan perangkat mobile, yang dapat membantu petani melakukan pemantauan

kondisi tanaman secara otomatis, cepat, dan akurat. Dengan hasil ini, penelitian dapat dikembangkan lebih lanjut menuju implementasi lapangan melalui integrasi model pada aplikasi berbasis Android atau sistem pertanian cerdas (*smart farming*).

5. Kesimpulan

Penelitian ini berhasil mengembangkan model MobileNetV2 berbasis *transfer Learning* yang mampu mengklasifikasikan penyakit daun cabai dengan performa sangat tinggi. Model menunjukkan akurasi sebesar 99%, *F1-score* rata-rata 0.99, dan loss rendah pada data validasi sebesar 0.07, dengan tingkat kesalahan klasifikasi hanya 0.73% dari total citra uji. Hasil ini membuktikan efektivitas optimasi *hyperparameter*, data augmentation, serta regularisasi dropout dalam menjaga keseimbangan antara akurasi dan kemampuan generalisasi model. Dengan demikian, model MobileNetV2 layak diterapkan sebagai sistem deteksi otomatis penyakit daun cabai berbasis citra digital untuk mendukung deteksi dini di sektor pertanian. Sebagai pengembangan lebih lanjut, penelitian selanjutnya dapat memperluas variasi dataset dengan kondisi pencahayaan dan varietas cabai yang lebih beragam serta mengeksplorasi arsitektur ringan lain seperti EfficientNet atau MobileNetV3 untuk

meningkatkan efisiensi inferensi pada perangkat berdaya rendah

6. Daftar Pustaka

- [1] H. Mukaromah, A. Ikhsanudin, F. Arianto, Ningsiah, and S. Lestari, "Penerapan Smart Farming Untuk Budidaya Cabai Dalam Greenhouse," *Aisyah J. Informatics Electr. Eng.*, vol. 5, no. 2, pp. 207–217, Aug. 2023, doi: 10.30604/jti.v5i2.227.
- [2] N. Putri Arafa, S. Rahma Basri, R. Ratnasari, and R. Adi Saputra, "Klasifikasi Penyakit Pada Daun Tanaman Cabai Dengan Pendekatan Artificial Neural Network (Ann)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 6, pp. 12865–12871, Nov. 2024, doi: 10.36040/jati.v8i6.12140.
- [3] L. S. Riva and J. Jayanta, "Deteksi Penyakit Tanaman Cabai Menggunakan Algoritma YOLOv5 Dengan Variasi Pembagian Data," *J. Inform. J. Pengemb. IT*, vol. 8, no. 3, pp. 248–254, Sep. 2023, doi: 10.30591/jpit.v8i3.5679.
- [4] C. T. Yen and C. Y. Tsao, "Lightweight Convolutional Neural Network For Chest X-Ray Images Classification," *Sci. Rep.*, vol. 14, no. 1, pp. 1–23, 2024, doi: 10.1038/s41598-024-80826-z.
- [5] M. D. R. Kamble, M. S. K. Gadale, M. D. N. Pawar, M. G. D. Shedage, and M. M. Mahajan, "Leaf Disease Detection System," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 12, no. 3, pp. 160–164, Mar. 2024, doi: 10.22214/ijraset.2024.58699.
- [6] M. J. Setiawan, Budi Nugroho, and Anggraini Puspita Sari, "Klasifikasi Penyakit Daun Tanaman Menggunakan Algoritma CNN dan Random Forest," *Teknologi*, vol. 13, no. 2, pp. 12–18, Jul. 2023, doi: 10.26594/teknologi.v13i2.3739.
- [7] Y. Zhang et al., "Early Detection And Lesion Visualization Of Pear Leaf Anthracnose Based On Multi-Source Feature Fusion Of Hyperspectral Imaging," *Front. Plant Sci.*, vol. 15, Oct. 2024, doi: 10.3389/fpls.2024.1461855.
- [8] P. T. U. Prasetyo, B. Santoso, and S. Kacung, "Sistem Deteksi Penyakit Pada Daun Tanaman Kentang Menggunakan Metode Cnn Arsitektur Vgg-Net," *J. Inform. Teknol. dan Sains*, vol. 7, no. 2, pp. 777–784, May 2025, doi: 10.51401/jinteks.v7i2.5758.
- [9] M. Saiful, L. M. Samsu, and F. rahman, "Sistem Deteksi Infeksi COVID-19 Pada Hasil X-Ray Rontgen Menggunakan Algoritma Convolutional Neural Network (CNN)," *Infotek J. Inform. dan Teknol.*, vol. 4, no. 2, pp. 217–227, Jul. 2021, doi: 10.29408/JIT.V4I2.3582.
- [10] Rohima, Hariyen Ulfa, Yuliani, Hafiz Maulana, L. Fimawahib, and Fauzi Erwis, "Akurasi Citra Image Penyakit Daun Kentang Berdasarkan Citra Sehat, Citra Early Blight, Dan Citra Late Blight Menggunakan Convolutional Neural Network (CNN)," *RJOCS (Riau J. Comput. Sci.)*, vol. 10, no. 2, pp. 167–175, Jul. 2024, doi: 10.30606/rjocs.v10i2.2862.
- [11] N. Bayu Aji, T. Raharjo Yudantoro, Z. Safitri, S. Beta Kuntardjo, and K. Santoso, "Application of MobileNetV2-Based Deep Learning in Detecting Diseases in Chili Plants," *J. Informatics, Inf. Syst. Softw. Eng. Appl.*, vol. 7, no. 2, pp. 203–212, 2025.
- [12] J. Yao, S. N. Tran, S. Sawyer, and S. Garg, "Machine Learning For Leaf Disease Classification: Data, Techniques And Applications," *Artif. Intell. Rev.*, vol. 56, no. S3, pp. 3571–3616, Dec. 2023, doi: 10.1007/s10462-023-10610-4.
- [13] C. Pal, S. Karmakar, I. Mukherjee, and P. P. Chakrabarti, "A Lightweight And Explainable CNN Model For Empowering Plant Disease Diagnosis," *Sci. Rep.*, vol. 15, no. 1, p. 30720, Aug. 2025, doi: 10.1038/s41598-025-94083-1.
- [14] S. Rahman, M. Elveny, M. Ramli, and D. Manurung, "Mobilechilinet: Convolutional Neural Network For Chili Leaves

- Classification," *IAES Int. J. Artif. Intell.*, vol. 14, no. 5, pp. 3757–3770, 2025, doi: 10.11591/ijai.v14.i5.pp3757-3770.
- [15] E. L. P. Ristanti, "Analisis Dan Perbandingan Arsitektur Vgg16 Dan Mobilenetv2 Untuk Klasifikasi Dan Identifikasi Penyakit Daun Pada Tanaman Cabai Menggunakan Cnn," *Sci. J. Ilm. Sains dan Teknol.*, vol. 2, no. 9, pp. 216–226, 2024, [Online]. Available: <https://doi.org/10.572349/scientica.v2i9.2381>
- [16] D. B. Daş, "An Intelligent and Light-weight Approach Based on MobileNetV 2 Architecture for Identifying Brain Tumors," vol. 8, no. 2, pp. 392–399, 2025, doi: 10.35377/saucis...
- [17] D. Chennamsetti, "Comparative Study of Deep Learning Techniques for Detecting Corn Plant Leaf Diseases Using Transfer Learning," *J. Adv. Plant Biol.*, vol. 1, no. 4, pp. 7–19, Apr. 2025, doi: <https://doi.org/10.14302/issn.2638-4469.japb-25-5395>.
- [18] M. Xu, S. Yoon, Y. Jeong, and D. S. Park, "Transfer Learning For Versatile Plant Disease Recognition Withlimited Data," *Front. Plant Sci.*, vol. 13, no. November, pp. 1–14, 2022, doi: 10.3389/fpls.2022.1010981.
- [19] F. Dubourvieux, G. Lapouge, A. Loesch, B. Luvison, and R. Audigier, "Cumulative Unsupervised Multi-Domain Adaptation For Holstein Cattle Re-Identification," *Artif. Intell. Agric.*, vol. 10, pp. 46–60, 2023, doi: 10.1016/j.aiia.2023.10.002.
- [20] I. Fathurrahman, M. Djamaruddin, Z. Amri, and M. N. Wathan, "Klasifikasi Motif Batik Nusantara Menggunakan Vision Transformer (ViT) Berbasis Deep Learning," *Infotek J. Inform. dan Teknol.*, vol. 8, no. 2, pp. 511–522, Jul. 2025, doi: 10.29408/JIT.V8I2.31108