

Klasifikasi Penyakit pada Daun Tanaman Cabai Menggunakan Metode Convolutional Neural Network

Muh. Afthar Algiffari¹, Abid Abdillah^{1*}, Amirah², Nurlindasari Tamsir²

¹Teknik Informatika, Universitas Dipa Makassar, Makassar, Indonesia

²Universitas Dipa Makassar, Makassar, Indonesia

e-mail: ¹afthar05@gmail.com, ²abidabdillah3.14@gmail.com, ³amirah@undipa.ac.id,
⁴nurlindasari@undipa.ac.id

Abstrak

Cabai rawit (*Capsicum frutescens* L.) merupakan komoditas hortikultura bernilai ekonomi tinggi, namun produktivitasnya sering menurun akibat penyakit daun. Identifikasi manual masih bergantung pada pengalaman petani sehingga rawan kesalahan karena kemiripan gejala antar penyakit. Penelitian ini bertujuan mengembangkan model klasifikasi Tanaman penyakit daun cabai rawit berbasis citra digital menggunakan metode Convolutional Neural Network (CNN) agar identifikasi dapat dilakukan secara otomatis, cepat, dan akurat. Dataset yang digunakan berjumlah 4.740 citra daun dengan enam kelas, yaitu Healthy Leaf, Cercospora Leaf Spot, Curl Virus, Nutrition Deficiency, White Spot, dan Bacterial Spot, yang diperoleh dari lahan pertanian Desa Kanaungan dan dataset publik Kaggle. Metode penelitian meliputi pre-processing, data augmentation, pembagian data latih, validasi, dan uji, serta pelatihan CNN menggunakan arsitektur MobileNetV2 dengan fine-tuning. Evaluasi dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score melalui confusion matrix. Hasil menunjukkan model CNN mampu mengklasifikasikan penyakit daun cabai rawit dengan testing accuracy 99,30%, sehingga berpotensi menjadi dasar pengembangan sistem deteksi penyakit tanaman berbasis kecerdasan buatan untuk mendukung produktivitas pertanian.

Kata kunci—Artificial Intelligence, Cabai Rawit, CNN, Computer Vision, Klasifikasi Penyakit.

Abstract

Chili pepper (*Capsicum frutescens* L.) is a high-value horticultural crop whose productivity often decreases due to leaf diseases. Manual identification depends on farmers' experience and is prone to errors because of similar visual symptoms. This study aims to develop an image-based classification model for chili leaf diseases using the Convolutional Neural Network (CNN) method to enable fast and accurate detection. The dataset contains 4,740 leaf images in six classes: Healthy Leaf, Cercospora Leaf Spot, Curl Virus, Nutrition Deficiency, White Spot, and Bacterial Spot, collected from Kanaungan Village fields and public Kaggle sources. The method includes image pre-processing, data augmentation, data splitting, and CNN training using the MobileNetV2 architecture with fine-tuning. Performance is evaluated using accuracy, precision, recall, and F1-score through a confusion matrix. The results indicate that the CNN model achieves a testing accuracy of 99.30%, showing potential for developing an AI-based plant disease detection system to support agricultural productivity.

Keywords—Artificial Intelligence, Cayenne Pepper, CNN, Computer Vision, Disease Classification.

1. PENDAHULUAN

Cabai rawit (*Capsicum frutescens* L.) merupakan komoditas pertanian bernilai ekonomi

tinggi dan banyak dikonsumsi oleh masyarakat Indonesia. Berdasarkan Badan Pusat Statistik (BPS, 2024), total produksi cabai rawit nasional mencapai lebih dari 2,9 juta ton per tahun. Tingginya permintaan menjadikannya tanaman strategis di sektor pertanian nasional, namun produktivitasnya sangat bergantung pada kesehatan daun yang rentan terhadap berbagai penyakit, termasuk infeksi patogen penyebab keriting daun yang dapat menurunkan hasil panen secara signifikan [1].

Bagian tanaman cabai rawit yang paling rentan terhadap serangan adalah daun, mengingat fungsinya yang krusial dalam fotosintesis serta paparannya yang langsung terhadap kondisi eksternal. Infeksi pada daun dapat mengakibatkan perubahan yang jelas pada aspek warna, morfologi, dan tekstur. Daun yang terjangkit patogen akan mengalami perubahan warna seperti bercak cokelat keabuan atau kekuningan [2]. Selain itu, bentuk daun dapat berubah menjadi melengkung atau terlipat, dan teksturnya kaku atau mudah patah sebagai akibat dari kerusakan jaringan seluler [3]. Kondisi ini menurunkan kemampuan fotosintesis dan kualitas hasil panen, sehingga deteksi dini penyakit daun menjadi penting karena gejalanya muncul lebih awal dibandingkan bagian tanaman lain [4].

Proses identifikasi penyakit daun cabai rawit hingga kini masih dilakukan secara manual melalui pengamatan visual oleh petani atau penyuluh pertanian. Namun, metode ini bergantung pada pengalaman pengamat dan kerap menimbulkan kesalahan diagnosis karena gejala penyakit daun yang memiliki kemiripan [5]. Akibatnya, penanganan sering terlambat dan produktivitas menurun; tanaman cabai rawit yang seharusnya menghasilkan sekitar 50–100 kg per tahun dapat kehilangan hampir setengah produksinya berdasarkan observasi lapangan. Oleh karena itu, pengembangan model deteksi otomatis berbasis AI diperlukan untuk meningkatkan akurasi identifikasi dan efisiensi pengendalian penyakit daun cabai rawit [6].

Kemajuan teknologi kecerdasan buatan (Artificial Intelligence), terutama dalam bidang Deep Learning, membuka peluang besar untuk mengatasi masalah tersebut. Salah satu algoritma yang paling efektif dalam mengenali pola visual kompleks adalah Convolutional Neural Network (CNN). CNN mampu mengekstraksi fitur citra secara otomatis tanpa rekayasa fitur manual dan terbukti unggul dalam pengolahan dataset citra dua dimensi seperti daun tanaman [7]. Berbagai studi menunjukkan bahwa CNN dapat mencapai akurasi deteksi penyakit tanaman antara 80%–90% pada berbagai jenis tanaman seperti tomat, padi, dan cabai rawit [7], [8], [9], [10].

Beberapa penelitian terdahulu telah mengkaji penggunaan CNN untuk deteksi penyakit tanaman. Naik et al. [7] mengembangkan model CNN untuk klasifikasi penyakit daun cabai menggunakan dataset Procedia dan mencapai akurasi yang kompetitif, namun cakupan kelasnya masih terbatas. Bezabh et al. [8] mengusulkan arsitektur CPD-CCNN berbasis konkatenasi model CNN untuk klasifikasi penyakit lada dan mencapai akurasi 93,2%, meskipun jumlah kelas yang diklasifikasikan masih sedikit. Hassan et al. [9] menunjukkan bahwa pendekatan transfer learning mampu meningkatkan performa model CNN pada dataset penyakit daun tanaman dengan akurasi rata-rata 85%–91%. Latif et al. [10] membuktikan bahwa CNN yang dikembangkan dengan arsitektur yang dioptimalkan mampu mencapai akurasi tinggi pada klasifikasi penyakit tanaman padi. Berdasarkan kajian tersebut, terdapat celah penelitian berupa minimnya studi yang mengklasifikasikan enam kelas penyakit daun cabai rawit sekaligus menggunakan MobileNetV2 dengan strategi two-phase fine-tuning pada dataset lokal yang divalidasi secara ilmiah.

Penelitian ini berfokus pada pengembangan model CNN menggunakan arsitektur MobileNetV2 dengan teknik transfer learning dan fine-tuning untuk mengklasifikasikan enam jenis penyakit daun cabai rawit secara otomatis, cepat, dan akurat. Dataset diperoleh dari lahan pertanian Desa Kanaungan dan platform Kaggle dengan total 4.740 citra yang telah divalidasi. Model yang dihasilkan diharapkan dapat menjadi dasar pengembangan sistem pendeteksi penyakit tanaman berbasis citra digital guna mendukung peningkatan produktivitas pertanian cabai rawit di Indonesia.

2. METODE PENELITIAN

2.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan mulai pada tanggal 1 Oktober hingga 1 Januari. Lokasi penelitian tempat pengambilan data dilakukan di lahan perkebunan cabai rawit yang berlokasi di Sempakan, Desa Kanaungan, Kecamatan Labakkang, Kabupaten Pangkajene dan Kepulauan, Sulawesi Selatan.

2.2 Jenis Penelitian

Penelitian ini termasuk dalam kategori penelitian kuantitatif, karena seluruh prosesnya berfokus pada pengumpulan dan analisis data dalam bentuk angka untuk memperoleh kesimpulan yang objektif. Pendekatan kuantitatif digunakan untuk mengukur, menghitung, dan mengevaluasi kinerja model klasifikasi penyakit daun cabai rawit berdasarkan hasil pengujian terhadap dataset citra, dengan metrik numerik seperti akurasi, presisi, recall, dan F1-score.

Selain bersifat kuantitatif, penelitian ini juga termasuk penelitian eksperimental karena melibatkan perlakuan langsung terhadap variabel penelitian. Peneliti melakukan serangkaian eksperimen terkontrol seperti pengaturan jumlah lapisan konvolusi, teknik augmentasi data, jenis optimizer, learning rate, dan jumlah epoch pelatihan untuk menentukan konfigurasi model CNN yang paling optimal dalam mengenali enam kategori penyakit daun cabai rawit.

2.3 Sumber Data Penelitian dan Metode Pengambilan Sampel

Data dalam penelitian ini terdiri atas data primer dan data sekunder yang digunakan untuk mendukung proses pelatihan dan pengujian model klasifikasi penyakit daun cabai rawit. Data primer diperoleh melalui pengambilan citra secara langsung di lahan perkebunan Desa Kanaungan menggunakan kamera smartphone dengan pencahayaan alami guna menghasilkan kualitas citra yang optimal. Proses pengambilan gambar dilakukan dengan jarak sekitar 10–15 cm dari objek daun dan menggunakan latar belakang polos untuk memudahkan tahap preprocessing serta meningkatkan akurasi ekstraksi fitur.

Data sekunder diperoleh dari dataset terbuka pada platform Kaggle yang menyediakan citra penyakit daun cabai rawit dengan label klasifikasi yang telah tersedia sebelumnya. Dataset tersebut digunakan sebagai data pendukung apabila jumlah data lapangan belum memenuhi target serta untuk memperkaya variasi citra berdasarkan kondisi pencahayaan, sudut pengambilan gambar, dan tingkat keparahan penyakit.

Validasi data dilakukan dalam dua tahap guna menjamin keakuratan label dan meminimalkan bias subjektif. Tahap pertama dilakukan oleh praktisi lokal, yaitu petani dan penyuluh pertanian yang memiliki pengalaman empiris dalam mengidentifikasi gejala penyakit daun cabai rawit di lapangan. Tahap kedua dilakukan oleh akademisi dari jurusan pertanian yang memiliki kompetensi dalam bidang patologi tanaman dan agronomi, sehingga proses pengelompokan citra berdasarkan kelas penyakit menjadi lebih terstandarisasi dan valid secara ilmiah.

Populasi penelitian mencakup sekitar 9.000 citra daun cabai rawit yang berasal dari dua sumber, yaitu sekitar 6.000 citra data primer dan 3.000 citra data sekunder. Penentuan jumlah sampel menggunakan rumus Slovin dengan margin of error sebesar 1%, sebagai berikut:

$$n = \frac{N}{1 + Ne^2} = \frac{9.000}{(1 + 9.000(0,01^2))} = \frac{9.000}{(1 + 0,9)} = 4.737 \approx 4.740 \quad (1)$$

Berdasarkan hasil perhitungan tersebut, jumlah sampel yang digunakan dalam penelitian ini sebanyak 4.740 citra. Sampel kemudian dibagi secara merata ke dalam enam kelas utama, sehingga masing-masing kelas terdiri atas 790 citra. Teknik pengambilan sampel yang diterapkan adalah purposive sampling, yaitu pemilihan data berdasarkan kriteria tertentu seperti kualitas citra, kejelasan visual gejala penyakit, serta kesesuaian label klasifikasi. Teknik ini dipilih untuk memastikan bahwa data yang digunakan benar-benar representatif dan relevan dengan tujuan penelitian.

2.4 Bahan dan Alat Penelitian

Peralatan yang digunakan meliputi: laptop dengan prosesor Intel Core i7 Generasi ke-12, RAM 16 GB, SSD 512 GB, dan GPU Intel Iris Xe; smartphone dengan resolusi 50 megapiksel untuk pengambilan citra daun; tripod setinggi 1 meter untuk menjaga kestabilan kamera; akses internet minimal 10 Mbps; dan Google Colab sebagai lingkungan pemrograman berbasis cloud.


Bahan penelitian meliputi dataset citra daun cabai rawit (*Capsicum frutescens* L.) enam kategori, serta perangkat lunak Python 3.10 dengan library TensorFlow dan Keras untuk membangun dan melatih model CNN, OpenCV untuk preprocessing citra, NumPy dan Pandas untuk pengelolaan data numerik, serta Matplotlib dan Seaborn untuk visualisasi hasil pelatihan dan evaluasi.

2.5 Metode Pengujian

Data yang digunakan sebanyak 4.740 citra yang terbagi menjadi 6 kelas dengan masing-masing kelas terdiri dari 790 citra. Dataset dibagi dengan rasio 70:15:15 sehingga setiap kelas memiliki 554 citra untuk pelatihan, 118 citra untuk validasi, dan 118 citra untuk pengujian.

Model yang digunakan adalah CNN dengan arsitektur MobileNetV2 berbasis transfer learning, dikompilasi menggunakan optimizer Adam dan loss function sparse categorical crossentropy, dengan batch size 32. Evaluasi model dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score, serta confusion matrix [11]. Ambang batas evaluasi ditetapkan minimal 80%, dengan performa ideal mendekati atau melebihi 90% sesuai standar penelitian klasifikasi citra.

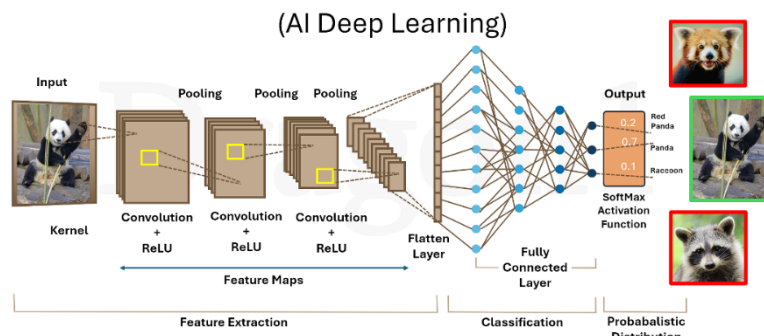
2.6 Prosedur Penelitian



Gambar 1. Prosedur penelitian

Prosedur penelitian dilakukan secara sistematis melalui tahapan berikut: (1) Pengumpulan citra daun cabai rawit dari lapangan dan sumber dataset publik; (2) Pre-processing data untuk memastikan kualitas dan kesiapan data sebelum proses pelatihan, meliputi tahapan seperti labelling, normalisasi nilai piksel, resize ukuran citra, dan teknik augmentasi data; (3) Pemodelan Convolutional Neural Network (CNN) sebagai metode utama dalam proses klasifikasi penyakit daun; (4) Pengujian dan evaluasi model untuk mengukur performa berdasarkan metrik yang telah ditentukan; (5) Analisis dan interpretasi hasil guna memahami kinerja model serta mengidentifikasi kelebihan dan keterbatasannya; serta (6) Penyusunan laporan penelitian sebagai tahap akhir yang merangkum seluruh proses dan hasil penelitian.

2.7 Arsitektur Model CNN (MobileNetV2)



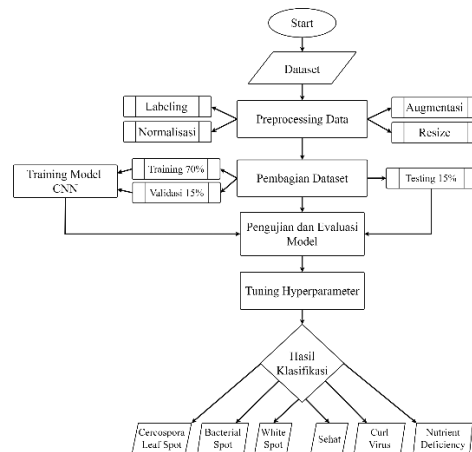
Gambar 2. Arsitektur umum CNN dengan layer konvolusi, pooling, dan fully connected

Model CNN dikembangkan menggunakan arsitektur MobileNetV2 yang dilatih sebelumnya pada dataset ImageNet melalui pendekatan transfer learning [12]. MobileNetV2 menggunakan depthwise separable convolution dan inverted residual block untuk mengurangi jumlah parameter tanpa mengorbankan akurasi [13]. Di atas base model ditambahkan lapisan Global Average Pooling untuk merangkum fitur spasial, Dropout (rate 0,5) sebagai regularisasi, serta Dense layer dengan 6 neuron dan aktivasi Softmax untuk klasifikasi enam kelas penyakit.

Pelatihan dilakukan dalam dua fase. Fase 1 (Initial Training): seluruh layer base model (0–99) dibekukan, hanya lapisan classifier yang dilatih dengan optimizer Adam ($lr=0,001$), maksimal 30 epoch, dengan callback EarlyStopping (patience=5) dan ReduceLROnPlateau (patience=3). Fase 2 (Fine-Tuning): layer 100 hingga akhir (54 dari 154 layer) di-unfreeze dengan learning rate 0,0001, maksimal 20 epoch, memungkinkan model menyesuaikan fitur tingkat tinggi dengan karakteristik dataset penyakit daun cabai rawit.

3. HASIL DAN PEMBAHASAN

3.1 Perancangan Solusi

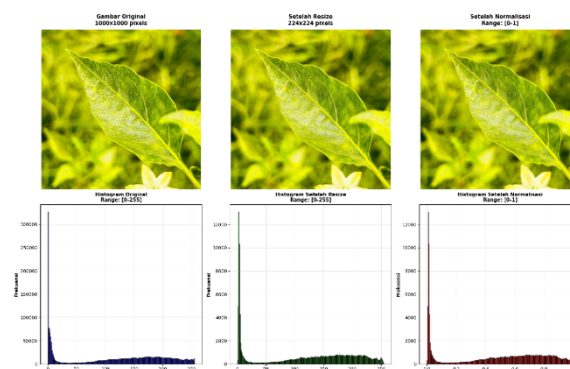


Gambar 3. Alur Perancangan Solusi Pembuatan Model CNN

Perancangan solusi dalam penelitian ini digambarkan melalui alur kerja sistematis yang mencakup seluruh tahapan proses, mulai dari pengumpulan data hingga menghasilkan output klasifikasi penyakit daun cabai rawit. Alur tersebut dapat dilihat pada Gambar 3 berikut.

3.2 Preprocessing Data

3.2.1 Resize dan Normalisasi



Gambar 4. Proses Normalisasi dan Resize pada dataset gambar

Seluruh citra memiliki resolusi awal yang bervariasi (tipikal 1.000×1.000 piksel). Dua proses standarisasi diterapkan secara berurutan. Pertama, normalisasi nilai piksel dengan mengonversi rentang $[0-255]$ menjadi $[0-1]$ dengan membagi setiap piksel dengan 255. Secara

visual citra tidak berubah, namun histogram menunjukkan pergeseran sumbu dari [0–255] ke [0–1] dengan pola distribusi yang identik. Normalisasi ini mempercepat konvergensi dan mencegah exploding/vanishing gradient selama backpropagation. Kedua, resize mengubah dimensi seluruh citra ke 224×224 piksel menggunakan interpolasi bilinear, sesuai dimensi input standar MobileNetV2. Jumlah piksel berkurang dari 1.000.000 menjadi 50.176, namun karakteristik visual diskriminatif seperti pola bercak dan tekstur daun tetap terjaga.

3.2.2 Augmentasi data



Gambar 5. Penerapan beberapa proses augmentasi pada dataset gambar


Augmentasi diterapkan eksklusif pada data training untuk meningkatkan keragaman data latih tanpa mempengaruhi evaluasi. Data validation dan testing menggunakan citra original untuk memastikan hasil evaluasi mencerminkan kondisi lapangan. Tujuh jenis transformasi diterapkan sebagaimana ditampilkan pada Gambar diatas dan dirangkum pada Tabel 1.

Tabel 1 Parameter yang digunakan dalam proses augmentasi

Transformasi	Parameter	Tujuan
Rotation	$\pm 30^\circ$	Rotation invariance
Width/Height Shift	$\pm 20\%$	Translation invariance
Zoom	$\pm 20\%$	Scale invariance
Horizontal & Vertical Flip	Aktif	Symmetry invariance
Shear	$\pm 20\%$	Robustness terhadap perspektif miring

3.2.3 Pembagian dataset dan pemberian label

Dataset citra daun cabai rawit memiliki populasi sebanyak 9.000 citra, namun sebanyak 4.740 citra dipilih sebagai sampel penelitian. Sampel tersebut kemudian dibagi secara proporsional ke dalam data training 70% (3.318 citra), data validation 15% (711 citra), dan data testing 15% (711 citra). Pembagian ini dilakukan untuk menjaga keseimbangan distribusi enam kelas penyakit serta memastikan proses pelatihan, validasi, dan evaluasi model CNN berjalan secara objektif dan terukur.



Gambar 6. Proporsi pembagian dataset serta distribusi data perkelasnya

Setiap citra pada sampel penelitian diberi label numerik 0–5 sesuai dengan enam kelas penyakit, yaitu Healthy Leaf, Cercospora Leaf Spot, White Spot, Bacterial Spot, Nutrition Deficiency, dan Curl Virus. Pelabelan ini berfungsi sebagai ground truth dalam pembelajaran terawasi (supervised learning), sehingga model CNN dapat memetakan fitur visual citra daun cabai rawit ke dalam skema klasifikasi multi-kelas secara akurat.



Gambar 7. Pemberian label numerik untuk setiap kelas penyakit

3.3 Proses Training

3.3.1 Initial Training (Fase 1)

```

=====
TRAINING FASE 1: 30 EPOCH (Base Model Frozen)
=====
Epoch 1/30
104/104 ----- 857s/step - accuracy: 0.5647 - loss: 1.2092 - val_accuracy: 0.9381 - val_loss: 0.1759 - learning_rate: 0.0010
Epoch 2/30
104/104 ----- 42s/step - accuracy: 0.8688 - loss: 0.3662 - val_accuracy: 0.9677 - val_loss: 0.1081 - learning_rate: 0.0010
Epoch 3/30
104/104 ----- 41s/step - accuracy: 0.9188 - loss: 0.2579 - val_accuracy: 0.9705 - val_loss: 0.0940 - learning_rate: 0.0010
Epoch 4/30
104/104 ----- 45s/step - accuracy: 0.9315 - loss: 0.1981 - val_accuracy: 0.9634 - val_loss: 0.1061 - learning_rate: 0.0010
Epoch 5/30
104/104 ----- 41s/step - accuracy: 0.9331 - loss: 0.1815 - val_accuracy: 0.9775 - val_loss: 0.0735 - learning_rate: 0.0010
Epoch 6/30
104/104 ----- 42s/step - accuracy: 0.9419 - loss: 0.1470 - val_accuracy: 0.9789 - val_loss: 0.0643 - learning_rate: 0.0010
Epoch 7/30
104/104 ----- 42s/step - accuracy: 0.9556 - loss: 0.1367 - val_accuracy: 0.9775 - val_loss: 0.0667 - learning_rate: 0.0010
Epoch 8/30
104/104 ----- 44s/step - accuracy: 0.9548 - loss: 0.1262 - val_accuracy: 0.9831 - val_loss: 0.0629 - learning_rate: 0.0010
Epoch 9/30
104/104 ----- 42s/step - accuracy: 0.9592 - loss: 0.1100 - val_accuracy: 0.9803 - val_loss: 0.0648 - learning_rate: 0.0010
Epoch 10/30
104/104 ----- 44s/step - accuracy: 0.9644 - loss: 0.0997 - val_accuracy: 0.9845 - val_loss: 0.0480 - learning_rate: 0.0010
Epoch 11/30
104/104 ----- 45s/step - accuracy: 0.9664 - loss: 0.1089 - val_accuracy: 0.9761 - val_loss: 0.0607 - learning_rate: 0.0010
Epoch 12/30
104/104 ----- 42s/step - accuracy: 0.9560 - loss: 0.1202 - val_accuracy: 0.9831 - val_loss: 0.0493 - learning_rate: 0.0010
Epoch 13/30
104/104 ----- 85s/step - accuracy: 0.9711 - loss: 0.0807 - val_accuracy: 0.9859 - val_loss: 0.0455 - learning_rate: 0.0010
Epoch 14/30
104/104 ----- 41s/step - accuracy: 0.9698 - loss: 0.0864 - val_accuracy: 0.9803 - val_loss: 0.0594 - learning_rate: 0.0010
Epoch 15/30
104/104 ----- 41s/step - accuracy: 0.9715 - loss: 0.0831 - val_accuracy: 0.9803 - val_loss: 0.0589 - learning_rate: 0.0010
Epoch 16/30
104/104 ----- 41s/step - accuracy: 0.9645 - loss: 0.0938 - val_accuracy: 0.9817 - val_loss: 0.0554 - learning_rate: 0.0010
Epoch 17/30
104/104 ----- 80s/step - accuracy: 0.9718 - loss: 0.0690 - val_accuracy: 0.9803 - val_loss: 0.0497 - learning_rate: 5.0000e-04
Epoch 18/30
104/104 ----- 41s/step - accuracy: 0.9777 - loss: 0.0604 - val_accuracy: 0.9817 - val_loss: 0.0466 - learning_rate: 5.0000e-04

```

Gambar 8. Proses pelatihan model CNN pada Initial Training (Fase 1)

Pada fase initial training, model menggunakan arsitektur MobileNetV2 dengan bobot pralatih dari ImageNet. Seluruh lapisan base model dibekukan (freeze) sehingga hanya lapisan klasifikasi tambahan yang dilatih. Di atas base model ditambahkan Global Average Pooling, Dropout (0,5), dan Dense beraktivasi softmax dengan enam neuron untuk klasifikasi enam kelas penyakit.

Model dikompilasi menggunakan optimizer Adam (learning rate 0,001) dan loss sparse categorical crossentropy. Pelatihan dilakukan selama maksimal 30 epoch dengan batch size 32, serta menerapkan EarlyStopping dan ReduceLROnPlateau untuk mencegah overfitting dan menyesuaikan learning rate secara adaptif. Hasil pelatihan menunjukkan validation accuracy mencapai 98,59% dengan selisih kecil antara akurasi training dan validation ($\pm 1-2\%$), yang mengindikasikan kemampuan generalisasi model yang baik. Fase ini menjadi tahap adaptasi awal sebelum dilakukan fine-tuning pada tahap berikutnya.

3.3.2 Fine Training (Fase 2)

```

=====
FINE TUNING FASE 2: 20 EPOCH
=====
[ ] Unfreeze from layer: 100
[ ] Total trainable layers: 54
Epoch 1/20 ----- 87s 510ms/step - accuracy: 0.8742 - loss: 0.4419 - val_accuracy: 0.9705 - val_loss: 0.1009 - learning_rate: 1.0000e-04
104/104 -----
Epoch 2/20 ----- 47s 355ms/step - accuracy: 0.9721 - loss: 0.0794 - val_accuracy: 0.9733 - val_loss: 0.0876 - learning_rate: 1.0000e-04
104/104 -----
Epoch 3/20 ----- 46s 351ms/step - accuracy: 0.9888 - loss: 0.0299 - val_accuracy: 0.9733 - val_loss: 0.0903 - learning_rate: 1.0000e-04
104/104 -----
Epoch 4/20 ----- 46s 344ms/step - accuracy: 0.9904 - loss: 0.0280 - val_accuracy: 0.9775 - val_loss: 0.0839 - learning_rate: 1.0000e-04
104/104 -----
Epoch 5/20 ----- 44s 327ms/step - accuracy: 0.9897 - loss: 0.0301 - val_accuracy: 0.9845 - val_loss: 0.0477 - learning_rate: 1.0000e-04
104/104 -----
Epoch 6/20 ----- 80s 318ms/step - accuracy: 0.9938 - loss: 0.0165 - val_accuracy: 0.9677 - val_loss: 0.1111 - learning_rate: 1.0000e-04
104/104 -----
Epoch 7/20 ----- 43s 313ms/step - accuracy: 0.9913 - loss: 0.0180 - val_accuracy: 0.9747 - val_loss: 0.0872 - learning_rate: 1.0000e-04
104/104 -----
Epoch 8/20 ----- 46s 340ms/step - accuracy: 0.9903 - loss: 0.0281 - val_accuracy: 0.9817 - val_loss: 0.0456 - learning_rate: 1.0000e-04
104/104 -----
Epoch 9/20 ----- 79s 311ms/step - accuracy: 0.9928 - loss: 0.0160 - val_accuracy: 0.9705 - val_loss: 0.0696 - learning_rate: 1.0000e-04
104/104 -----
Epoch 10/20 ----- 43s 313ms/step - accuracy: 0.9953 - loss: 0.0141 - val_accuracy: 0.9887 - val_loss: 0.0275 - learning_rate: 1.0000e-04
104/104 -----
Epoch 11/20 ----- 82s 323ms/step - accuracy: 0.9966 - loss: 0.0142 - val_accuracy: 0.9887 - val_loss: 0.0245 - learning_rate: 1.0000e-04
104/104 -----
Epoch 12/20 ----- 44s 341ms/step - accuracy: 0.9936 - loss: 0.0166 - val_accuracy: 0.9873 - val_loss: 0.0198 - learning_rate: 1.0000e-04
104/104 -----
Epoch 13/20 ----- 41s 303ms/step - accuracy: 0.9937 - loss: 0.0183 - val_accuracy: 0.9845 - val_loss: 0.0272 - learning_rate: 1.0000e-04
104/104 -----
Epoch 14/20 ----- 43s 312ms/step - accuracy: 0.9944 - loss: 0.0128 - val_accuracy: 0.9873 - val_loss: 0.0429 - learning_rate: 1.0000e-04
104/104 -----
Epoch 15/20 ----- 44s 320ms/step - accuracy: 0.9948 - loss: 0.0135 - val_accuracy: 0.9845 - val_loss: 0.0448 - learning_rate: 1.0000e-04
104/104 -----
Epoch 16/20 ----- 82s 323ms/step - accuracy: 0.9972 - loss: 0.0110 - val_accuracy: 0.9859 - val_loss: 0.0290 - learning_rate: 5.0000e-05
104/104 -----
Epoch 17/20 ----- 81s 325ms/step - accuracy: 0.9951 - loss: 0.0098 - val_accuracy: 0.9859 - val_loss: 0.0301 - learning_rate: 5.0000e-05
104/104 -----

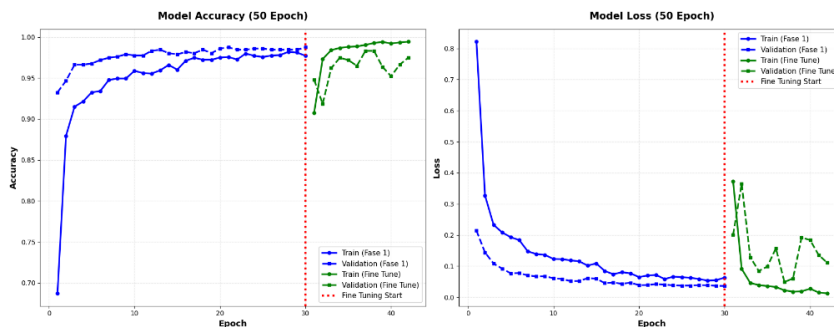
```

Gambar 9. Proses pelatihan model CNN pada Fine Training (Fase 2)

Setelah fase initial training mencapai performa stabil, proses dilanjutkan ke tahap fine-tuning menggunakan model terbaik dari fase sebelumnya. Pada tahap ini, sebagian lapisan pada arsitektur MobileNetV2 dibuka secara selektif. Layer 0–99 tetap dibekukan untuk mempertahankan fitur dasar, sedangkan layer ke-100 hingga akhir di-unfreeze agar dapat menyesuaikan fitur tingkat tinggi dengan karakteristik spesifik dataset penyakit daun cabai.

Model kemudian dikompilasi ulang menggunakan optimizer Adam dengan learning rate 0,0001 (sepuluh kali lebih kecil dari fase 1) untuk memastikan pembaruan bobot berlangsung lebih halus dan stabil. Proses pelatihan dilakukan selama maksimum 20 epoch dengan batch size 32, serta tetap menerapkan EarlyStopping dan ReduceLRonPlateau guna menjaga efisiensi dan mencegah overfitting.

Hasil fine-tuning menunjukkan peningkatan performa dibandingkan fase sebelumnya, dengan validation accuracy mencapai 98,87% dan validation loss sekitar 0,02. Selisih antara training dan validation accuracy tetap kecil (<1%), yang menunjukkan generalisasi model tetap terjaga. Karena peningkatan performa telah mencapai kondisi konvergen dan tidak menunjukkan indikasi overfitting, proses pelatihan dihentikan pada fase ini. Model hasil fine-tuning kemudian digunakan sebagai model akhir untuk tahap evaluasi pada data testing. Berikut ini grafik untuk proses trainingnya.



Gambar 10. Grafik akurasi dan loss proses training

Secara ringkas, perbandingan hasil pelatihan antara Fase 1 (Initial Training) dan Fase 2 (Fine-Tuning) disajikan pada Tabel 2 berikut:


Tabel 2. Perbandingan Hasil Pelatihan Fase 1 dan Fase 2

Metrik	Fase 1 (Initial Training)	Fase 2 (Fine-Tuning)
Training Accuracy	98,37%	99,72%
Validation Accuracy	98,59%	98,87%
Validation Loss	0,0455	0,0198
Gap Train-Val Accuracy	±1–2%	0,85%

Metrik	Fase 1 (Initial Training)	Fase 2 (Fine-Tuning)
Learning Rate	0,001	0,0001
Layer Dilatih	Classifier saja (base	Layer 100–154 +
Max Epoch	30	20

3.4 Evaluasi Confusion Matrix

Evaluasi kinerja model pada data testing dilakukan menggunakan confusion matrix, yang menyajikan perbandingan antara label sebenarnya (true label) dan label hasil prediksi (predicted label). Sumbu vertikal menunjukkan kelas aktual, sedangkan sumbu horizontal menunjukkan kelas hasil prediksi. Nilai pada diagonal utama merepresentasikan jumlah prediksi benar (true positive), sementara nilai di luar diagonal menunjukkan kesalahan klasifikasi.



Gambar 11. Tabel *Ground of Truth Confusion matriks Multi-Class*

Berdasarkan gambar diatas, terlihat bahwa sebagian besar nilai terkonsentrasi pada diagonal utama, yang menunjukkan tingkat akurasi klasifikasi yang sangat tinggi. Kelas Healthy Leaf, Cercospora Leaf Spot, White Spot, dan Curl Virus mencapai akurasi 100%, di mana seluruh sampel pada masing-masing kelas berhasil diprediksi dengan benar tanpa kesalahan.

Pada kelas Bacterial Spot, sebanyak 116 dari 119 sampel (97,5%) berhasil diklasifikasikan dengan benar, dengan 3 sampel salah diprediksi sebagai Cercospora Leaf Spot. Sementara itu, kelas Nutrition Deficiency menunjukkan 117 dari 119 prediksi benar (98,3%), dengan masing-masing 1 sampel keliru diprediksi sebagai Healthy Leaf dan Bacterial Spot.

Secara keseluruhan, dominasi nilai pada diagonal utama pada gambar tersebut mengindikasikan bahwa model memiliki kemampuan diskriminasi yang sangat baik antar kelas. Kesalahan klasifikasi yang terjadi relatif kecil dan umumnya muncul pada kelas yang memiliki kemiripan karakteristik visual. Hasil ini menunjukkan bahwa model mampu melakukan identifikasi penyakit daun cabai secara akurat dan konsisten pada data pengujian.

3.5 Analisis Precision, Recall, dan F1-Score

Tabel 3. Hasil analisis Classification Report

Kelas	Precicion	Recall	F1-Score
Healthy Leaf	0.99	1.00	1.00
Cercospora Leaf Spot	0.98	1.00	0.99
White Spot	1.00	1.00	1.00
Bacterial Spot	0.99	0.97	0.98
Nutrition Deficiency	1.00	0.98	0.99
Curl Virus	1.00	1.00	1.00

Kelas Healthy Leaf, Cercospora Leaf Spot, White Spot, dan Curl Virus mencapai F1-score sempurna (1.00). Kelas Bacterial Spot memperoleh F1-score 0.98; kesalahan terjadi pada 3 sampel yang diprediksi sebagai Cercospora Leaf Spot akibat kemiripan pola bercak. Kelas

Nutrition Deficiency memperoleh F1-score 0.99; 2 sampel salah diprediksi ke kelas lain karena gejala awal klorosis menyerupai daun sehat.

Verifikasi perhitungan manual untuk kelas White Spot sebagai contoh: TP=119, FP=0, FN=0, sehingga Precision = $119/(119+0) = 1.00$; Recall = $119/(119+0) = 1.00$; F1-Score = $2 \times (1.00 \times 1.00) / (1.00 + 1.00) = 1.00$. Hasil ini mengkonfirmasi bahwa ciri visual White Spot berupa bercak putih yang kontras sangat distingtif sehingga mudah dikenali model.

3.6 Pembahasan

Perancangan alur kerja sistematis dari preprocessing hingga pelatihan dua fase terbukti menghasilkan model yang stabil. Testing accuracy 99,30% melampaui target minimal 80% yang ditetapkan. Dibandingkan penelitian terdahulu, Putra [14] mencapai akurasi 91,3% dengan tiga kelas, sedangkan Balakeswara [15] memperoleh 93,2%. Penelitian serupa yang menggunakan CNN dan transfer learning pada penyakit daun tanaman umumnya mencapai akurasi antara 85%–96% [9], [10], [12]. Penelitian ini mengembangkan enam kelas dengan transfer learning berbasis MobileNetV2, memberikan peningkatan signifikan dalam cakupan kelas dan performa.

Temuan baru penelitian ini adalah adanya kesalahan klasifikasi pada Bacterial Spot dan Nutrition Deficiency akibat kemiripan pola visual, yang membuka peluang penelitian lanjutan menggunakan ensemble learning atau penambahan fitur untuk mengatasi ambiguitas visual tersebut.

Dari sisi kontribusi ilmiah, model yang dikembangkan memberikan beberapa manfaat yang signifikan. Pertama, strategi two-phase fine-tuning terbukti mampu meningkatkan validation accuracy sebesar 0,28 poin persentase sekaligus menurunkan validation loss sebesar 56,48% (dari 0,0455 menjadi 0,0198). Penurunan loss yang substansial ini mengindikasikan model tidak hanya lebih akurat tetapi juga lebih terkalibrasi dalam menghasilkan probabilitas prediksi. Kedua, performa per kelas yang merata dengan F1-score minimum 0,98 menunjukkan bahwa model tidak bias terhadap kelas tertentu, kondisi yang krusial mengingat setiap jenis penyakit memerlukan penanganan berbeda. Ketiga, arsitektur MobileNetV2 yang dipilih memiliki keunggulan efisiensi komputasi dibandingkan arsitektur berat seperti VGG-16 atau ResNet-50 [12], sehingga model ini berpotensi dijalankan pada perangkat dengan sumber daya terbatas sebagai fondasi sistem deteksi penyakit tanaman berbasis kecerdasan buatan.

4. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan sebagai berikut:

1. Alur kerja sistematis yang mencakup pengumpulan 4.740 citra dari 6 kelas penyakit, preprocessing (resize 224×224 , normalisasi 0–1), augmentasi data, pembagian dataset (70:15:15), dan pelatihan dua fase menghasilkan model stabil dengan validation accuracy meningkat dari 98,59% (fase 1) menjadi 98,87% (fase 2).
2. Parameter optimal (Adam, learning rate 0,001→0,0001, batch size 32, EarlyStopping, ReduceLRonPlateau) menghasilkan gap minimal 0,85% antara training accuracy (99,72%) dan validation accuracy (98,87%), membuktikan tidak ada overfitting signifikan.
3. Model mencapai testing accuracy 99,30%, melampaui target minimal 80%. Performa per kelas: White Spot, Curl Virus, dan Healthy Leaf (F1: 100%); Cercospora Leaf Spot dan Nutrition Deficiency (F1: 99%); Bacterial Spot (F1: 98%). Hanya 5 dari 711 sampel (0,70%) salah diklasifikasikan.
4. Transfer learning berbasis MobileNetV2 dengan two-phase training terbukti efektif, ditandai penurunan validation loss 56,48% (0,0455→0,0198), menjadikan model adaptif dan layak sebagai dasar sistem deteksi penyakit berbasis AI.

5. SARAN

Beberapa saran untuk penelitian lebih lanjut:

1. Kembangkan model menjadi aplikasi mobile/web real-time untuk deteksi dini penyakit daun cabai di lapangan.
2. Tingkatkan variasi dataset dengan citra dari berbagai kondisi lingkungan, fase pertumbuhan, dan lokasi geografis yang lebih beragam.
3. Tingkatkan akurasi klasifikasi Bacterial Spot dan Nutrition Deficiency melalui ensemble learning atau penambahan fitur visual tambahan.
4. Lakukan uji coba langsung dengan petani sebagai pengguna akhir untuk mendapatkan feedback terkait akurasi dan kemudahan penggunaan di kondisi lapangan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Dipa Makassar atas dukungan akademik dalam penyelesaian penelitian ini, serta kepada para petani dan penyuluh pertanian di Desa Kanaungan, Kecamatan Labakkang, atas kontribusi dalam proses pengumpulan dan validasi data.

DAFTAR PUSTAKA

- [1] Y. Avianto, N. K. Sari, and A. B. Pratama, "Synergistic Effects of Photosynthetic Bacteria and Endophytes: A Novel Approach to Enhance Cayenne Pepper Productivity," *JURNAL AGRONOMI TANAMAN TROPIKA (JUATIKA)*, vol. 6, no. 3, pp. 699-711-699 – 711, Sep. 2024, doi: 10.36378/juatika.v6i3.3673.
- [2] P. Salaria, S. Jain, R. D. Bhardwaj, R. Rani, and S. Jhanji, "Physiological and biochemical responses of chilli pepper (*Capsicum annuum* L.) to sudden wilt syndrome," *Physiol. Mol. Plant Pathol.*, vol. 126, p. 102038, Jul. 2023, doi: 10.1016/j.pmpp.2023.102038.
- [3] Z. Aslam et al., "EFFECT OF INTEGRATED NUTRIENT MANAGEMENT PRACTICES ON PHYSIOLOGICAL, MORPHOLOGICAL AND YIELD PARAMETERS OF CHILLI (*CAPSICUM ANNUM* L.)," *Pak. J. Bot.*, vol. 54, no. 6, pp. 2143-2150, 2022, doi: 10.30848/PJB2022-6(40).
- [4] K. B and Dr. Z. A. K. N, "Deep Learning-Based CNN Approach for Disease Detection in Chili Plant Leaves", doi: 10.5281/ZENODO.18106459.
- [5] Y. D. Wulandari, L. C. Munggaran, F. A. Setiawan, and I. A. Satya, "Chili Leaf Health Classification using Xception Pretrained Model," *Sistemasi: Jurnal Sistem Informasi*, vol. 13, no. 3, pp. 1084-1093, May 2024, doi: 10.32520/stmsi.v13i3.3943.
- [6] M. Mahmood ur Rehman, J. Liu, A. Nijabat, M. Faheem, W. Wang, and S. Zhao, "Leveraging Convolutional Neural Networks for Disease Detection in Vegetables: A Comprehensive Review," *Agronomy* 2024, Vol. 14, no. 10, Sep. 2024, doi: 10.3390/agronomy14102231.
- [7] B. N. Naik, R. Malmathanraj, and P. Palanisamy, "Detection and classification of chilli leaf disease using a squeeze-and-excitation-based CNN model," *Ecol. Inform.*, vol. 69, p. 101663, Jul. 2022, doi: 10.1016/j.ecoinf.2022.101663.
- [8] Y. A. Bezabih, A. O. Salau, B. M. Abuhayi, A. A. Mussa, and A. M. Ayalew, "CPD-CCNN: classification of pepper disease using a concatenation of convolutional neural network models," *Scientific Reports* 2023 13:1, vol. 13, no. 1, pp. 15581-, Sep. 2023, doi: 10.1038/s41598-023-42843-2.
- [9] S. M. Hassan, A. K. Maji, M. Jasiński, Z. Leonowicz, and E. Jasińska, "Identification of Plant-Leaf Diseases Using CNN and Transfer-Learning Approach," *Electronics* 2021, Vol.

- 10, vol. 10, no. 12, Jun. 2021, doi: 10.3390/ELECTRONICS10121388.
- [10] G. Latif, S. E. Abdelhamid, R. E. Mallouhy, J. Alghazo, and Z. A. Kazimi, "Deep Learning Utilization in Agriculture: Detection of Rice Plant Diseases Using an Improved CNN Model," *Plants* 2022, Vol. 11, no. 17, Aug. 2022, doi: 10.3390/plants11172230.
- [11] D. M. W. Powers, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation," Oct. 2020, Accessed: Mar. 06, 2026. [Online]. Available: <http://arxiv.org/abs/2010.16061>
- [12] N. Abou Baker, N. Zengeler, and U. Handmann, "A Transfer Learning Evaluation of Deep Neural Networks for Image Classification," *Machine Learning and Knowledge Extraction* 2022, Vol. 4, Pages 22-41, vol. 4, no. 1, pp. 22–41, Jan. 2022, doi: 10.3390/make4010002.
- [13] A. Howard et al., "Searching for MobileNetV3," 2019.
- [14] A. Putra, "Klasifikasi Penyakit Daun Cabai Dengan Metode CNN Untuk Deteksi Awal," *Jurnal Profesi Insinyur Universitas Lampung*, vol. 6, no. 1, Jun. 2025, doi: 10.23960/jpi.v6n1.147.
- [15] I. Putu Nandi Balakeswara, "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK PADA SISTEM KLASIFIKASI PENYAKIT CABAI MENGGUNAKAN CITRA DAUN."
-