

## **Deteksi Penyakit Tanaman Cabai Berbasis Deep Learning Menggunakan Convolutional Neural Network Secara Realtime**

**Yogi Mulyana Prayoga<sup>1\*</sup>, Deasy Wahyuni<sup>2</sup>, Elisawati<sup>3</sup>**

<sup>1,2,3)</sup> Program Studi Teknik Informatika, Universitas Dumai

Jl. Utama Karya Bukit Batrem 2 Dumai, Riau

Email:[yogimulyana496@gmail.com](mailto:yogimulyana496@gmail.com)<sup>1</sup>, [deasywahyuni1@gmail.com](mailto:deasywahyuni1@gmail.com)<sup>2</sup>, [elisawati112@gmail.com](mailto:elisawati112@gmail.com)<sup>3</sup>

### **ABSTRAK**

Cabai merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi di Indonesia, namun rentan terhadap serangan berbagai penyakit seperti daun keriting, virus *gemini*, *antraknosa*, layu, serangan *whitefly*, dan ulat grayak. Deteksi secara dini terhadap penyakit-penyakit ini sangat krusial guna mencegah kerugian hasil panen. Penelitian ini bertujuan mengembangkan sistem pendekripsi penyakit pada tanaman cabai menggunakan pendekatan *deep learning* dengan arsitektur *Convolutional Neural Network* (CNN), khususnya menggunakan model *MobileNet* yang dikenal efisien dalam klasifikasi citra. Sistem dikembangkan agar dapat beroperasi secara *real-time* melalui kamera perangkat. Proses pengembangan mengikuti metode *Waterfall* dalam *Software Development Life Cycle* (SDLC), meliputi tahap perencanaan, analisis, perancangan, implementasi, hingga pengujian. Berdasarkan hasil uji coba, sistem menunjukkan tingkat akurasi yang tinggi dalam mengklasifikasikan daun cabai sehat dan yang terinfeksi penyakit. Diharapkan sistem ini dapat menjadi alat bantu bagi petani dalam mendeteksi penyakit lebih awal dan mengambil langkah preventif secara cepat, sehingga dapat menunjang peningkatan produktivitas hasil pertanian cabai.

**Kata kunci:** Tanaman cabai, *deep learning*, CNN, *MobileNet*, deteksi penyakit dini

### **ABSTRACT**

*Chili peppers are a high-value horticultural commodity in Indonesia but are vulnerable to various plant diseases such as curly leaves, Gemini virus, anthracnose, wilt, whitefly infestation, and armyworms. Early detection of these diseases is essential to prevent significant yield losses. This study aims to develop a chili disease detection system using a deep learning approach with a Convolutional Neural Network (CNN) architecture, specifically employing the MobileNet model, which is known for its efficiency in image classification tasks. The system is designed to operate in real-time using a device camera. Development follows the Waterfall model of the Software Development Life Cycle (SDLC), encompassing planning, analysis, design, implementation, and testing phases. Testing results indicate that the system achieves high accuracy in distinguishing between healthy and diseased chili leaves. This system is expected to assist farmers in early detection and prompt preventive actions, ultimately supporting increased productivity in chili cultivation.*

**Keywords:** *Chili plant, deep learning, CNN, MobileNet, early disease detection*

## Pendahuluan

Cabai (*Capsicum spp.*) merupakan salah satu komoditas hortikultura yang bernilai ekonomi tinggi dan memiliki peran penting dalam perekonomian nasional. Di Indonesia, cabai tidak hanya menjadi bahan pangan utama dalam berbagai masakan, tetapi juga memiliki permintaan yang terus meningkat, baik untuk kebutuhan domestik maupun ekspor. Namun produktivitas tanaman cabai sering terganggu oleh penyakit seperti keriting, virus *geminii*, bercak daun, layu *fusarium*, buah busuk *antraknosa*, dan layu bakteri, yang dapat mengurangi kuantitas, kualitas, dan nilai jual hasil panen.

Metode deteksi penyakit yang umum digunakan saat ini masih mengandalkan observasi manual oleh petani. Pendekatan ini bersifat subjektif, memerlukan waktu lama, dan akurasinya rendah, terutama bagi petani yang tidak memiliki latar belakang agronomi formal. Akibatnya, banyak infeksi terdeteksi terlambat sehingga penanganannya kurang efektif dan menimbulkan kerugian besar.

Kemajuan dalam teknologi *deep learning* dan pemrosesan citra digital telah membuka peluang untuk deteksi penyakit tanaman yang lebih cepat dan tepat. Khususnya, Convolutional Neural Networks (CNN) terbukti efektif dalam klasifikasi citra penyakit tanaman. Penelitian Sri Winiarti *et al.* di Universitas Ahmad Dahlan berhasil mengembangkan aplikasi berbasis smartphone untuk deteksi penyakit cabai, dengan akurasi validasi mencapai 94 % dan skor pengguna  $90\% \pm$  (Winiarti *et al.*, 2024). Selanjutnya, Liza Puspita *et al.* (2025) menerapkan model MobileNet untuk klasifikasi penyakit daun cabai dan mencapai akurasi tes sekitar 84,8 % (Puspita Putri *et al.*, 2025).

Dalam studi internasional, (Dai *et al.*, 2023) memperkenalkan arsitektur ringan GoogLeNet-EL dengan akurasi ~97,87 % pada dataset berisi enam penyakit daun cabai; model ini lebih efisien dan lebih cepat dibanding arsitektur seperti *MobileNet-V2*, *ResNet*, dan *AlexNet*. Selain itu, Si & Kim (2024) mengembangkan metode CRASA berbasis Autoencoder serial dan GAN untuk mendeteksi penyakit cabai lewat *image reconstruction*, dengan performa tinggi dalam klasifikasi anomalous (Si & Kim, 2024) berhasil melakukan diagnosis layu *antraknosa* pada cabai menggunakan CNN, dengan evaluasi terhadap lebih dari 1.000 sampel penyakit di *Plant Pathology Journal*.

Studi perbandingan antara arsitektur CNN dan MobileNetV2 oleh (Achmad Naila Muna Ramadhani *et al.*, 2023). di Jurnal RESTI (2023) menunjukkan bahwa MobileNetV2 memiliki performa optimal dengan akurasi 90 %, recall dan F1-score sekitar 92 %. Ini menjelaskan keunggulan arsitektur ringan seperti *MobileNet* dalam memproses citra penyakit tanaman secara efisien.

Selain itu, penelitian nasional oleh (Nurdiansyah *et al.*, 2024) memberikan tinjauan literatur tentang klasifikasi penyakit tanaman cabai menggunakan pendekatan CNN dan *transfer learning*, serta menunjukkan potensi tinggi metode ini dalam meningkatkan akurasi deteksi penyakit cabai (Saputra *et al.*, 2021).

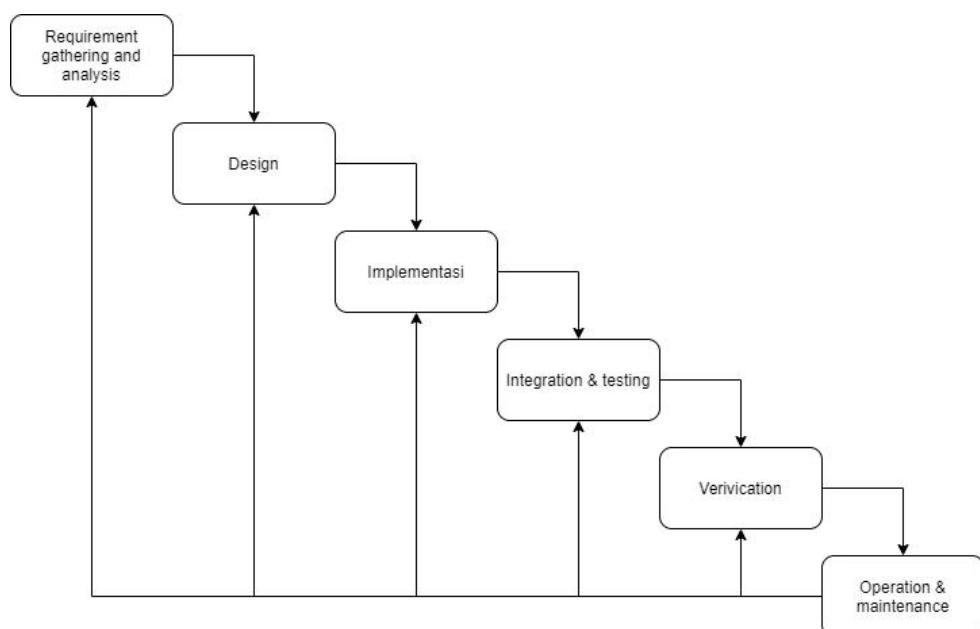
Meskipun keberhasilan model CNN dan *MobileNet* telah terbukti dalam konteks laboratorium atau dataset historis, terdapat kebutuhan mendesak untuk mengembangkan sistem deteksi *real-time* berbasis kamera perangkat agar dapat diimplementasikan langsung di lapangan.

Penelitian ini bertujuan untuk menerapkan arsitektur CNN berbasis *MobileNet* guna mendeteksi penyakit pada tanaman cabai secara *real-time* melalui kamera perangkat, serta meningkatkan efisiensi dan akurasi dalam proses deteksi dibandingkan metode manual. Dengan demikian, sistem yang dikembangkan diharapkan dapat membantu petani dalam melakukan deteksi dini penyakit cabai secara cepat, akurat, dan langsung di lapangan. Implementasi teknologi ini

diharapkan mampu meningkatkan produktivitas, meminimalkan potensi kerugian akibat serangan penyakit, serta mendorong keberlanjutan usaha pertanian cabai di Indonesia.

## Metode Penelitian

Penelitian ini menggunakan metode *Software Development Life Cycle* (SDLC) model *Waterfall* dalam pengembangan sistem deteksi penyakit tanaman cabai berbasis *deep learning* menggunakan *Convolutional Neural Network* secara *real-time*. Model *Waterfall* dipilih karena memiliki tahapan yang sistematis dan terstruktur, sehingga setiap tahap harus diselesaikan sebelum melanjutkan ke tahap berikutnya. Adapun tahapan dalam metode ini meliputi:



Gambar 1. Metode SDLC model *waterfall*

Berikut ini adalah penjelasan alur penelitian:

1. *Requirement Analysis* (Analisis Kebutuhan)

Tahap ini bertujuan untuk mengidentifikasi kebutuhan sistem yang akan dikembangkan. Dalam penelitian ini, kebutuhan sistem meliputi:

- a. Dataset gambar daun cabai yang sehat dan terinfeksi berbagai jenis penyakit.
- b. Arsitektur *Convolutional Neural Network* (CNN) yang akan digunakan, seperti *MobileNet*.
- c. Perangkat keras dan perangkat lunak yang mendukung *real-time*.

2. *System Design* (Perancangan Sistem)

Pada tahap ini, dilakukan perancangan deteksi penyakit tanaman cabai, yang mencakup:

- a. Perancangan arsitektur CNN untuk klasifikasi penyakit pada daun cabai.

b. Desain antarmuka aplikasi deteksi penyakit yang memungkinkan pengguna mengambil gambar dan mendapatkan hasil diagnosis secara *real-time*.

3. *Implementation* (Implementasi)

Tahap ini melibatkan pengembangan sistem berdasarkan perancangan yang telah dibuat, meliputi:

a. Pengumpulan dan pemrosesan dataset gambar daun cabai yang terkena penyakit.

b. Melakukan teknik *data augmentation* seperti rotasi, flipping, dan perubahan kecerahan untuk meningkatkan keragaman dataset.

c. Pelatihan model CNN

- Menggunakan arsitektur *MobileNet*, yang memiliki efisiensi tinggi dalam parameter model dan memberikan akurasi lebih baik dibandingkan CNN konvensional.

- Model terdiri dari beberapa lapisan utama, termasuk:

- 1) *Input Layer* untuk menerima gambar berukuran 64x64.

- 2) *Convolutional Layers* dengan *kernel* 3×3 untuk mengekstrak fitur dari citra daun cabai.

- 3) *Batch Normalization* untuk meningkatkan stabilitas pelatihan.

- 4) *Global Average Pooling Layer* (GAP)

- 5) *Fully Connected Layers* yang menggunakan *Softmax* pada *output layer* untuk mengklasifikasikan penyakit daun cabai ke dalam beberapa kategori.

- 6) Proses *Feedforward & Klasifikasi*

d. Implementasi sistem deteksi penyakit dalam aplikasi berbasis desktop atau mobile menggunakan TensorFlow Lite atau OpenCV untuk mendukung *real-time inference*.

4. *Testing* (Pengujian)

Pengujian dilakukan untuk memastikan bahwa sistem dapat mendeteksi penyakit tanaman cabai dengan akurasi tinggi dan dalam waktu yang cepat. Pengujian dilakukan dalam dua tahap:

a. Pengujian Model Menggunakan dataset uji untuk mengevaluasi akurasi, presisi, recall, dan F1-score dari model CNN yang telah dilatih.

b. Pengujian sistem menguji kecepatan deteksi penyakit secara *real-time* dengan mengambil gambar langsung melalui kamera perangkat dan memeriksa respons sistem.

5. *Deployment & Maintenance* (Penerapan dan Pemeliharaan)

Setelah sistem berhasil diuji dan mendapatkan hasil yang optimal, sistem akan diterapkan dan diuji coba dalam skenario nyata di lingkungan pertanian. Pemeliharaan sistem dilakukan dengan pembaruan dataset, penyesuaian model jika ditemukan kesalahan klasifikasi, serta optimalisasi agar sistem dapat berjalan lebih cepat dan efisien.

## Hasil dan Pembahasan

**Tabel 1.** Dataset cabai

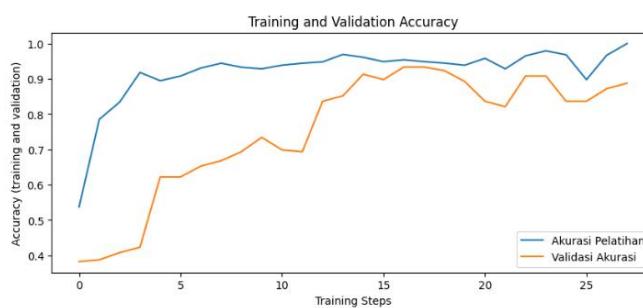
Jenis Penyakit	Jumlah gambar	Gambar
Antraknosa	250	
Bercak Daun	250	
Layu	250	
Whitefly	250	
Daun Berlubang / Hama Ulat Grayak	250	
Virus Kuning / Virus Gemini	250	
Daun Sehat	250	
Buah Sehat	250	
Daun Keriting	250	

Penelitian ini bertujuan mengembangkan sistem deteksi penyakit pada tanaman cabai menggunakan arsitektur *Convolutional Neural Network* (CNN) *MobileNetV1* secara *real-time*. Proses diawali dengan pengumpulan data gambar dari tiga sumber: Kaggle, Roboflow, dan dokumentasi langsung dari kebun cabai. Dataset ini diklasifikasikan menjadi sembilan kelas, terdiri dari tujuh kategori penyakit serta daun dan buah cabai sehat. Masing-masing kelas memiliki 250 citra, dengan

total 2.250 gambar yang dibagi ke dalam data pelatihan (80%), validasi (12%), dan pengujian (8%), disajikan pada Tabel 1.

Arsitektur *MobileNetV1* dipilih karena memiliki keunggulan pada efisiensi komputasi tanpa mengorbankan akurasi, sehingga cocok untuk implementasi di perangkat mobile. Model dilatih pada platform *Google Colaboratory* dengan input gambar berukuran 64x64 piksel dan tiga kanal warna. Beberapa lapisan ditambahkan untuk meningkatkan akurasi klasifikasi, seperti *Conv2D*, *Dropout*, *Global Average Pooling 2D*, *Flatten*, dan *Dense layer*. Selama pelatihan, diterapkan teknik *Early Stopping* untuk mencegah *overfitting*.

Hasil pelatihan ditunjukkan melalui kurva akurasi dan loss. Pada epoch ke-28, model mencapai akurasi pelatihan sebesar 0,9352 dan akurasi validasi sebesar 0,9358, seperti terlihat pada gambar 2.



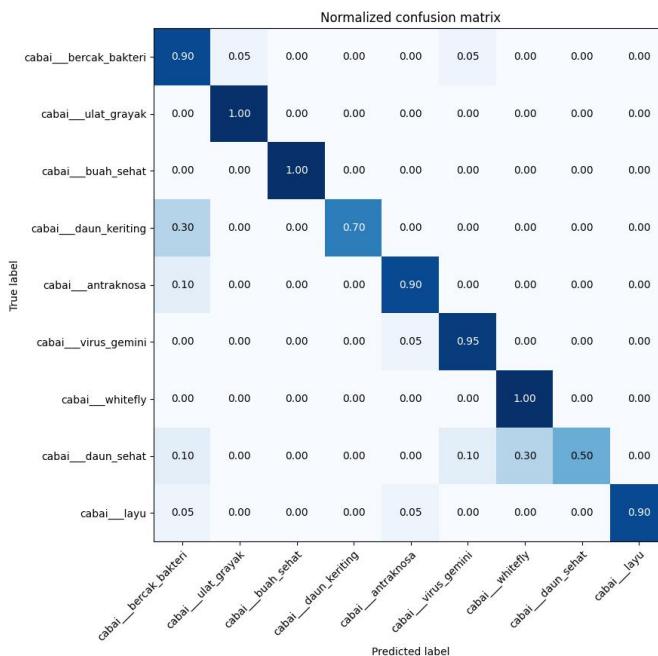
**Gambar 2.** Kurva akurasi training dan validasi menggunakan arsitektur *MobileNetV1*

Sedangkan nilai loss masing-masing sebesar 0,2976 (pelatihan) dan 0,2499 (validasi), yang ditampilkan pada gambar 3. Kurva ini menunjukkan bahwa proses pelatihan berlangsung stabil dan tidak mengalami *overfitting* yang signifikan.



**Gambar 3.** Kurva *loss training* dan validasi menggunakan arsitektur *Mobilenetv1*

Evaluasi model dilakukan menggunakan confusion matrix pada gambar 4 yang memperlihatkan performa klasifikasi untuk setiap kelas.



**Gambar 4.** Confusion matrix menggunakan arsitektur *MobileNetV1*

Meski secara umum menunjukkan performa baik, beberapa kelas seperti bercak bakteri dan daun keriting memiliki nilai akurasi prediksi yang lebih rendah. Hal ini kemungkinan disebabkan oleh kemiripan visual antar kelas. Pengujian sistem pada perangkat Android dilakukan dengan dua metode: (1) mengimpor gambar dari galeri, dan (2) menggunakan kamera secara real-time. Pada pengujian dengan galeri (tabel 2), dari 45 data uji, hanya terjadi 6 kesalahan klasifikasi yang ditampilkan sebagai berikut.

**Tabel 2.** Data uji android import gambar galeri menggunakan arsitektur MobileNetV1

Uji ke-	Data uji	Hasil prediksi (tingkat probabilitas)	Benar/salah
1	Bercak Bakteri	Bercak Bakteri (55.43%)	Benar
2	Bercak Bakteri	Bercak Bakteri (99.05%)	Benar
3	Bercak Bakteri	Daun sehat (99.99%)	Salah
4	Bercak Bakteri	Daun sehat (100%)	Salah
5	Bercak Bakteri	Daun sehat (99.99%)	Salah
6	Buah antraknosa	Buah antraknosa (99.99%)	Benar
7	Buah antraknosa	Ulat grayak (99.97)	Salah
8	Buah antraknosa	Buah antraknosa (99.99%)	Benar
9	Buah antraknosa	Buah antraknosa (99.46)	Benar
10	Buah antraknosa	Buah antraknosa (100%)	Benar
11	Daun layu	Daun layu (100%)	Benar
12	Daun layu	Daun layu (99.95%)	Benar
13	Daun layu	Daun keriting(88.84%)	Salah
14	Daun layu	Daun layu (100%)	Benar
15	Daun layu	Daun layu (100%)	Benar
16	Daun keriting	Daun keriting (98.24%)	Benar
17	Daun keriting	Daun keriting (96.81%)	Benar
18	Daun keriting	Daun keriting (98.05%)	Benar

<b>Uji ke-</b>	<b>Data uji</b>	<b>Hasil prediksi (tingkat probabilitas)</b>	<b>Benar/salah</b>
19	Daun keriting	Daun keriting (98.59%)	Benar
20	Daun keriting	Whitefly (96.80%)	Salah
21	Virus gemini	Virus gemini (99.52)	Benar
22	Virus gemini	Virus gemini (100%)	Benar
23	Virus gemini	Virus gemini (99.98%)	Benar
24	Virus gemini	Virus gemini (62.82)	Benar
25	Virus gemini	Virus gemini (99%)	Benar
26	Whitefly	Whitefly (100%)	Benar
27	Whitefly	Whitefly (75.59%)	Benar
28	Whitefly	Whitefly (99.99%)	Benar
29	Whitefly	Whitefly (99.07%)	Benar
30	Whitefly	Whitefly (99.99%)	Benar
31	Daun sehat	Daun sehat (100%)	Benar
32	Daun sehat	Daun sehat (100%)	Benar
33	Daun sehat	Daun sehat (100%)	Benar
34	Daun sehat	Daun sehat (97.71%)	Benar
35	Daun sehat	Daun sehat (100%)	Benar
36	Buah sehat	Buah sehat (100%)	Benar
37	Buah sehat	Buah sehat (99.99%)	Benar
38	Buah sehat	Buah sehat (100%)	Benar
39	Buah sehat	Buah sehat (100%)	Benar
40	Buah sehat	Buah sehat (100%)	Benar
41	Ulat grayak	Ulat grayak (99.97%)	Benar
42	Ulat grayak	Ulat grayak (99.99%)	Benar
43	Ulat grayak	Ulat grayak (100%)	Benar
44	Ulat grayak	Ulat grayak (99.87%)	Benar
45	Ulat grayak	Ulat grayak (53.14%)	Benar

Sebaliknya, pada pengujian real-time dengan kamera (Tabel 3), terdapat 9 kesalahan klasifikasi dari 45 data uji. Kesalahan ini dapat disebabkan oleh kualitas pencahayaan atau sudut pengambilan gambar yang memengaruhi kemampuan model dalam mengenali fitur visual.

**Tabel 3.** Data uji android kamera (*real time*) menggunakan arsitektur MobileNetV1

<b>Uji ke-</b>	<b>Data uji</b>	<b>Hasil prediksi (tingkat probabilitas)</b>	<b>Benar/salah</b>
1	Bercak Bakteri	Ulat grayak (56,92%)	Salah
2	Bercak Bakteri	Ulat grayak (99,94%)	Salah
3	Bercak Bakteri	Ulat grayak (99,71%)	Salah
4	Bercak Bakteri	Ulat grayak (87,83%)	Salah
5	Bercak Bakteri	Whitefly (84,75%)	Salah
6	Buah antraknosa	Buah antraknosa (72,96%)	Benar
7	Buah antraknosa	Whitefly (84,21%)	Salah
8	Buah antraknosa	Buah antraknosa (78,87%)	Benar
9	Buah antraknosa	Buah antraknosa (99,93%)	Benar
10	Buah antraknosa	Buah antraknosa (100%)	Benar
11	Daun layu	Daun layu (100%)	Benar
12	Daun layu	Daun layu (93,17%)	Benar
13	Daun layu	Daun layu (100%)	Benar
14	Daun layu	Daun layu (98,41%)	Benar
15	Daun layu	Ulat grayak (65,95%)	Salah

<b>Uji ke-</b>	<b>Data uji</b>	<b>Hasil prediksi (tingkat probabilitas)</b>	<b>Benar/salah</b>
16	Daun keriting	Daun sehat (94,87%)	Salah
17	Daun keriting	Bercak bakteri (99,41%)	Salah
18	Daun keriting	Daun keriting (93,52%)	Benar
19	Daun keriting	Daun keriting (49,68%)	Benar
20	Daun keriting	Daun keriting (98,97%)	Benar
21	Virus gemini	Ulat grayak (98,91%)	Salah
22	Virus gemini	Virus gemini (79,02%)	Benar
23	Virus gemini	Virus gemini (100%)	Benar
24	Virus gemini	Virus gemini (99,98%)	Benar
25	Virus gemini	Virus gemini (88,40%)	Benar
26	Whitefly	Whitefly (99,14%)	Benar
27	Whitefly	Whitefly (97,42%)	Benar
28	Whitefly	Whitefly (99,65%)	Benar
29	Whitefly	Whitefly (95,23%)	Benar
30	Whitefly	Whitefly (99,97%)	Benar
31	Daun sehat	Daun sehat (98,41%)	Benar
32	Daun sehat	Daun sehat (99,68%)	Benar
33	Daun sehat	Daun sehat (100%)	Benar
34	Daun sehat	Daun sehat (85,01%)	Benar
35	Daun sehat	Daun sehat (99,97%)	Benar
36	Buah sehat	Buah sehat (100%)	Benar
37	Buah sehat	Buah sehat (98,06%)	Benar
38	Buah sehat	Buah sehat (99,98%)	Benar
39	Buah sehat	Buah sehat (96,25%)	Benar
40	Buah sehat	Buah sehat (100%)	Benar
41	Ulat grayak	Ulat grayak (99,93%)	Benar
42	Ulat grayak	Ulat grayak (99,91%)	Benar
43	Ulat grayak	Ulat grayak (99,98%)	Benar
44	Ulat grayak	Ulat grayak (99,79%)	Benar
45	Ulat grayak	Ulat grayak (99,39%)	Benar

Tingkat akurasi model juga diperkuat dengan penghitungan evaluasi manual menggunakan confusion matrix. Sebagai contoh, pada klasifikasi buah cabai dengan penyakit antraknosa, model memperoleh precision sebesar 1,00, recall sebesar 0,80, dan F1-score sebesar 0,89. Hasil ini sejalan dengan output evaluasi otomatis Google Colab (gambar 5), yang memperlihatkan bahwa model bekerja secara andal dalam mengenali jenis penyakit tertentu.

```
Classification Report:
precision    recall   f1-score   :
cabai__antraknosa      1.00      0.80      0.89
cabai__bercak_bakteri  0.00      0.00      0.00
cabai__buah_sehat       1.00      1.00      1.00
cabai__daun_keriting    1.00      0.60      0.75
cabai__daun_sehat       0.83      1.00      0.91
cabai__layu              1.00      0.80      0.89
cabai__ulat_grayak      0.45      1.00      0.62
cabai__virus_gemini     1.00      0.80      0.89
cabai__whitefly          0.71      1.00      0.83
```

**Gambar 5.** Perhitungan menggunakan google colab

Implementasi MobileNetV1 dalam sistem ini terbukti dapat menghasilkan klasifikasi penyakit yang akurat dan efisien di perangkat Android, baik melalui input galeri maupun kamera. Hasil ini konsisten dengan temuan sebelumnya yang menyatakan bahwa model ringan seperti MobileNet cocok untuk deployment di perangkat edge/mobile dengan performa klasifikasi tinggi, sebagaimana ditunjukkan oleh penelitian sebelumnya (Winiarti et al., 2024) (Puspita Putri et al., 2025), serta pengujian dan perbandingan performa model ringan di perangkat bergerak (Achmad Naila Muna Ramadhani et al., 2023) (Nurdiansyah et al., 2024). Selain itu, efisiensi MobileNetV1 dalam klasifikasi citra juga diperkuat oleh studi pada perangkat Android oleh Winiarti dan Khoirunnisa, serta dukungan dari beberapa penelitian lain yang relevan (Bukhari, n.d.) (Kahfi Ash Shiddiq et al., n.d.) (Tsany & Dzaky, n.d.).

## Simpulan

Penelitian ini berhasil mengembangkan sistem deteksi penyakit tanaman cabai secara real-time menggunakan arsitektur *Convolutional Neural Network* (CNN) *MobileNetV1*, yang diimplementasikan pada perangkat Android. Model dilatih menggunakan dataset sebanyak 2.250 citra dari sembilan kelas, termasuk tujuh jenis penyakit dan dua kondisi sehat. Proses pelatihan menggunakan *Google Colaboratory* menunjukkan hasil akurasi pelatihan sebesar 93,52% dan validasi sebesar 93,58%, dengan nilai loss yang stabil pada akhir epoch. Pengujian menggunakan aplikasi Android menunjukkan bahwa sistem mampu mengidentifikasi penyakit dengan akurasi yang cukup tinggi, baik saat menggunakan gambar dari galeri (dengan 6 kesalahan dari 45 data) maupun pengujian real-time dengan kamera (dengan 9 kesalahan dari 45 data). Evaluasi lanjutan menggunakan confusion matrix dan perhitungan metrik seperti precision, recall, dan F1-score pada kelas penyakit tertentu (misalnya buah antraktosa) menunjukkan bahwa model memiliki performa klasifikasi yang andal, dengan F1-score mencapai 0,89. Implementasi model *MobileNetV1* terbukti efisien dan cocok untuk digunakan di perangkat dengan daya komputasi terbatas, serta mampu bekerja secara real-time dalam kondisi lapangan. Hal ini menunjukkan bahwa sistem yang dikembangkan berpotensi menjadi solusi praktis dan efektif dalam membantu petani melakukan deteksi dini penyakit pada tanaman cabai.

## Daftar Pustaka

- Achmad Naila Muna Ramadhani, Galuh Wilujeng Saraswati, Rama Tri Agung, & Heru Agus Santoso. (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>

- Bukhari, S. A. (n.d.). *Implementasi Metode Convolutional Neural Network (CNN) Untuk Diagnosa Penyakit Tanaman Cabai Pada Citra Daun.* <https://ejournal.warunayama.org/kohesi>
- Dai, M., Sun, W., Wang, L., Dorjoy, M. M. H., Zhang, S., Miao, H., Han, L., Zhang, X., & Wang, M. (2023). Pepper leaf disease recognition based on enhanced lightweight convolutional neural networks. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1230886>
- Kahfi Ash Shiddiq, A., Dzikrullah Syahputra, T., & Islam Negeri Alauddin Makassar, U. (n.d.). *Deteksi Penyakit pada Tanaman Padi Menggunakan MobileNet Transfer Learning Berbasis Android.* 2(2), 2022.
- Nurdiansyah, F., Fandyani, L., Ilyas Faisal, M., & Rohman Fadhilah. Reza. (2024). *Literatur Riview Klasifikasi Penyakit Tanaman Cabai Dengan Pendekatan CNN Dan Transfer Learning.* *OKTAL: Jurnal Ilmu Komputer dan Science*, 3(3), 2651–2655.
- Puspita Putri, L., Rafi Muttaqin, M., Raymond Ramadhan, Y., Informatika, T., & Wastukancana, S. (2025). *Klasifikasi Penyakit Daun Cabai Menggunakan Model MobileNet.* In *TeknoIS: Jurnal Ilmiah Teknologi Informasi dan Sains* (Vol. 15). <https://teknois.unbin.ac.id/JBS/>
- Saputra, R. A., Wasylanti, S., Supriyatna, A., & Saefudin, D. F. (2021). *Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi.* *JURNAL SWABUMI*, 9(2). <https://archive.ics.uci.edu/ml/datasets/Rice>
- Si, J., & Kim, S. (2024). CRASA: Chili Pepper Disease Diagnosis via Image Reconstruction Using Background Removal and Generative Adversarial Serial Autoencoder. *Sensors*, 24(21). <https://doi.org/10.3390/s24216892>
- Tsany, A., & Dzaky, R. (n.d.). *Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network.*
- Winiarti, S., Khoirunnisa, I. I., & Seman, N. (2024). *Mobile Application Development for Chili Disease Detection with Convolutional Neural Network.* *International Journal of Informatics and Computation (IJICOM)*, 6(2). <https://doi.org/10.35842/ijicom>