

BAB II TINJAUAN PUSTAKA

A. Penelitian Terkait

Tabel 1 Tabel Penelitian Terkait

No	Penulis (Tahun)	Keterangan
(1)	(2)	(3)
1	Rodríguez-Lira <i>et al.</i> (2024) [3]	Judul: <i>Trends in Machine and Deep learning Techniques for Plant Disease Identification: A Systematic Review.</i> Metode: Systematic literature review terhadap penerapan <i>machine learning</i> dan <i>Deep learning</i> untuk identifikasi penyakit tanaman. Hasil: Penelitian menunjukkan bahwa <i>machine learning</i> dan <i>Deep learning</i> banyak digunakan dalam identifikasi penyakit tanaman berbasis citra digital. CNN menjadi salah satu metode yang banyak diterapkan karena mampu mempelajari fitur visual secara otomatis. Keterkaitan/Perbedaan: Relevan karena mendukung penggunaan <i>Deep learning</i>, khususnya CNN, untuk deteksi penyakit daun tanaman. Perbedaannya, penelitian tersebut berupa kajian literatur, sedangkan penelitian ini melakukan pembangunan dan pengujian model CNN menggunakan arsitektur VGG16, ResNet50, dan MobileNetV2.
2	Tian <i>et al.</i> (2022) [10]	Judul: <i>Tomato Leaf Diseases Recognition Based on Deep Convolutional Neural Networks.</i> Metode: <i>Deep Convolutional Neural Network</i> untuk pengenalan penyakit daun tomat berbasis citra digital. Hasil: Penelitian menunjukkan bahwa <i>deep Convolutional Neural Network</i> dapat digunakan untuk mengenali penyakit daun tomat berdasarkan citra daun. Keterkaitan/Perbedaan: Relevan karena sama-sama membahas deteksi penyakit daun

		tanaman menggunakan CNN. Perbedaannya, penelitian ini membandingkan tiga arsitektur CNN, yaitu VGG16, ResNet50, dan MobileNetV2.
3	Pacal <i>et al.</i> (2024) [4]	Judul: <i>A Systematic Review of Deep learning Techniques for Plant Diseases.</i> Metode: <i>Systematic literature review</i> mengenai teknik <i>Deep learning</i> untuk deteksi dan deteksi penyakit tanaman. Hasil: Penelitian menunjukkan bahwa <i>Deep learning</i> memiliki perkembangan yang signifikan dalam deteksi penyakit tanaman, terutama pada deteksi citra daun. Keterkaitan/Perbedaan: Relevan karena memberikan dasar teori mengenai penggunaan <i>Deep learning</i> pada penyakit tanaman. Perbedaannya, penelitian tersebut bersifat kajian literatur, sedangkan penelitian ini melakukan eksperimen langsung terhadap tiga arsitektur CNN.
4	Muslih dan Krismawan (2024) [5]	Judul: <i>Tomato Leaf Diseases Classification using Convolutional Neural Networks with Transfer learning ResNet-50.</i> Metode: CNN dengan <i>transfer learning</i> menggunakan arsitektur ResNet50 untuk deteksi penyakit daun. Hasil: Penelitian menunjukkan bahwa ResNet50 dengan <i>transfer learning</i> dapat digunakan untuk deteksi penyakit daun tomat berbasis citra digital. Keterkaitan/Perbedaan: Relevan karena menggunakan ResNet50, salah satu arsitektur yang juga digunakan dalam penelitian ini. Perbedaannya, penelitian tersebut hanya berfokus pada ResNet50, sedangkan penelitian ini membandingkan ResNet50 dengan VGG16 dan MobileNetV2.
5	Attallah (2023) [6]	Judul: <i>Tomato Leaf Disease Classification via Compact Convolutional Neural Networks with Transfer learning and Feature Selection.</i> Metode: <i>Compact CNN, transfer learning,</i>

		dan <i>feature selection</i> untuk deteksi penyakit daun. Hasil: Penelitian menunjukkan bahwa CNN dengan <i>transfer learning</i> dapat membantu meningkatkan performa deteksi penyakit daun tomat. Keterkaitan/Perbedaan: Relevan karena membahas penerapan CNN dan <i>transfer learning</i> pada deteksi penyakit daun tanaman. Perbedaannya, penelitian tersebut menggunakan <i>Compact CNN</i> dan <i>feature selection</i>, sedangkan penelitian ini membandingkan arsitektur VGG16, ResNet50, dan MobileNetV2.
6	Mamatha G. dan Raju (2025) [11]	Judul: <i>Comparative Analysis of Deep learning Models for Tomato Leaf Disease Classification: Insights and Opportunities.</i> Metode: Perbandingan beberapa model <i>Deep learning</i> untuk deteksi penyakit daun. Hasil: Penelitian menunjukkan bahwa perbedaan model <i>Deep learning</i> dapat menghasilkan performa deteksi yang berbeda pada penyakit daun tomat. Keterkaitan/Perbedaan: Sangat relevan karena sama-sama membahas perbandingan model <i>Deep learning</i> untuk deteksi penyakit daun tanaman. Perbedaannya, penelitian ini difokuskan pada pembangunan model deteksi berbasis CNN dengan arsitektur VGG16, ResNet50, dan MobileNetV2 dalam satu skenario penelitian.
7	Sharma et al. (2025) [12]	Judul: <i>Deep learning Based Ensemble Model for Accurate Tomato Leaf Disease Classification by Leveraging ResNet50 and MobileNetV2 Architectures.</i> Metode: <i>Ensemble Deep learning</i> dengan memanfaatkan arsitektur ResNet50 dan MobileNetV2 untuk deteksi penyakit daun. Hasil: Penelitian menunjukkan bahwa kombinasi ResNet50 dan MobileNetV2 dapat digunakan untuk meningkatkan performa deteksi penyakit daun.

		Keterkaitan/Perbedaan: Relevan karena menggunakan ResNet50 dan MobileNetV2, yang juga digunakan dalam penelitian ini. Perbedaannya, penelitian tersebut menggunakan pendekatan <i>ensemble</i>, sedangkan penelitian ini membandingkan masing-masing arsitektur CNN secara terpisah.
8	Arifin dan Insani (2025) [13]	Judul: <i>Comparative Analysis of CNN, SVM, Decision Tree, Random Forest, and KNN for Maize Leaf Disease Detection Using Color and Texture Feature extraction.</i> Metode: Perbandingan CNN, SVM, <i>Decision Tree</i>, <i>Random Forest</i>, dan KNN untuk deteksi penyakit daun jagung menggunakan fitur warna dan tekstur. Hasil: Penelitian menunjukkan bahwa CNN dan metode <i>machine learning</i> konvensional dapat digunakan untuk deteksi penyakit daun tanaman, tetapi metode konvensional umumnya memerlukan proses ekstraksi fitur terlebih dahulu. Keterkaitan/Perbedaan: Relevan karena menjelaskan adanya metode lain selain CNN, seperti SVM, KNN, <i>Decision Tree</i>, dan <i>Random Forest</i>. Perbedaannya, penelitian tersebut membandingkan CNN dengan metode non-CNN, sedangkan penelitian ini berfokus pada perbandingan tiga arsitektur CNN, yaitu VGG16, ResNet50, dan MobileNetV2.
9	Hukkeri et al. (2024) [14]	Judul: <i>Classification of Various Plant Leaf Disease Using Pretrained CNN Models.</i> Metode: <i>Pretrained CNN models</i> untuk deteksi berbagai penyakit daun tanaman. Hasil: Penelitian menunjukkan bahwa <i>CNN pretrained models</i> dapat digunakan untuk deteksi penyakit daun tanaman dengan hasil yang baik. Keterkaitan/Perbedaan: Relevan karena sama-sama menggunakan pendekatan <i>CNN pretrained</i> untuk deteksi penyakit daun


		tanaman. Perbedaannya, penelitian ini secara khusus membandingkan VGG16, ResNet50, dan MobileNetV2 berdasarkan metrik <i>accuracy</i> , <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> .
10	Utami <i>et al.</i> (2025) [15]	Judul: <i>Implementation and Comparative Analysis of CNN and Transfer learning Models (EfficientNetB0, MobileNetV2, and ResNet50) for Rice Leaf Disease Detection Based on Digital Images.</i> Metode: CNN dan <i>transfer learning</i> menggunakan EfficientNetB0, MobileNetV2, dan ResNet50 untuk deteksi penyakit daun padi. Hasil: Penelitian menunjukkan bahwa model CNN dan <i>transfer learning</i> dapat digunakan untuk deteksi penyakit daun padi berbasis citra digital. Keterkaitan/Perbedaan: Relevan karena sama-sama membandingkan model CNN dan <i>transfer learning</i> pada deteksi penyakit daun tanaman. Perbedaannya, penelitian tersebut menggunakan objek daun padi dan arsitektur EfficientNetB0, sedangkan penelitian ini menggunakan VGG16, ResNet50, dan MobileNetV2.
11	Math dan Dharwadkar (2023) [16]	Judul: <i>Deep learning and Computer Vision for Leaf Miner Infestation Severity Detection on Muskmelon (Cucumis melo) Leaves.</i> Metode: Penelitian menggunakan pendekatan <i>Deep learning</i> berbasis Detectron2 untuk mendeteksi, melokalisasi, dan menentukan tingkat keparahan serangan leaf miner pada daun muskmelon. Hasil: Model mampu mendeteksi lokasi serangan leaf miner dan mengelompokkan tingkat keparahan serangan berdasarkan citra daun muskmelon. Keterkaitan dan perbedaan: Penelitian tersebut relevan karena menggunakan objek daun muskmelon dan pengolahan citra berbasis <i>Deep learning</i>. Perbedaannya, penelitian tersebut berfokus pada deteksi

		objek dan tingkat keparahan serangan hama, sedangkan penelitian ini berfokus pada deteksi empat kelas kondisi daun menggunakan VGG16, ResNet50, dan MobileNetV2.
12	Kang, Tamrakar, dan Kim (2025) [17]	Judul: <i>Improving Oriental Melon Leaf Disease Classification via DCGAN-Based Image Augmentation.</i> Metode: Penelitian melakukan deteksi penyakit daun oriental melon menggunakan CNN. Untuk mengatasi keterbatasan jumlah data, penelitian menerapkan augmentasi tradisional, DCGAN, serta modified DCGAN dengan residual connection dan beberapa fungsi aktivasi. Hasil: Augmentasi menggunakan modified DCGAN menghasilkan citra dengan variasi dan karakteristik kelas yang lebih baik serta meningkatkan performa model deteksi penyakit daun oriental melon. Keterkaitan dan perbedaan: Penelitian tersebut sangat relevan karena sama-sama melakukan deteksi penyakit daun melon berbasis citra digital. Perbedaannya, penelitian tersebut berfokus pada peningkatan kualitas dan jumlah data menggunakan DCGAN, sedangkan penelitian ini berfokus pada perbandingan performa tiga arsitektur <i>transfer learning</i> dengan skenario eksperimen yang sama.
13	Kannan et al. (2025) [18]	Judul: <i>Improving Farming by Quickly Detecting Muskmelon Plant Diseases Using Advanced Ensemble Learning and Capsule Networks.</i> Metode: Penelitian menggunakan ensemble learning yang menggabungkan Multi-Class Capsule Network dengan model pretrained menggunakan mekanisme majority voting. Model dibandingkan dengan ResNet101, VGG19, dan GoogleNet. Hasil: Pendekatan ensemble digunakan untuk meningkatkan ketepatan deteksi dini

		penyakit dan hama pada tanaman muskmelon. Keterkaitan dan perbedaan: Penelitian tersebut relevan karena menggunakan objek muskmelon dan membandingkan beberapa model <i>Deep learning</i>. Perbedaannya, penelitian tersebut menggunakan ensemble learning dan capsule network, sedangkan penelitian ini mengevaluasi VGG16, ResNet50, dan MobileNetV2 secara terpisah menggunakan <i>accuracy</i>, <i>precision</i>, <i>recall</i>, <i>F1-score</i>, <i>classification report</i>, dan <i>confusion matrix</i>.
--	--	---

Sumber : Hasil olahan peneliti, 2026.

Diagram *Mind Map* dicontohkan pada gambar berikut ini:



Gambar 1 *Mind Map* Penelitian

B. Landasan Teori

1. Artificial Intelligence

Artificial Intelligence atau kecerdasan buatan merupakan bidang ilmu komputer yang berfokus pada pengembangan sistem yang mampu mengenali pola, mengambil keputusan, dan menyelesaikan permasalahan secara otomatis. Dalam bidang pertanian, *Artificial Intelligence* dapat digunakan untuk membantu proses identifikasi penyakit tanaman melalui analisis data dan citra digital. Pemanfaatan *Artificial Intelligence* dalam identifikasi penyakit tanaman menjadi penting karena proses pengamatan manual masih memiliki keterbatasan, seperti subjektivitas pengamatan, ketergantungan terhadap pengalaman manusia, dan membutuhkan waktu yang relatif lama [3], [4].

Pada penelitian ini, *Artificial Intelligence* digunakan sebagai dasar konseptual dalam pengembangan model deteksi penyakit daun tanaman berbasis citra digital. Pembahasan *Artificial Intelligence* tidak diarahkan pada seluruh cabang kecerdasan buatan, tetapi difokuskan pada penerapannya dalam deteksi citra menggunakan pendekatan *Deep learning* berbasis *Convolutional Neural Network*.

2. Machine learning

Machine learning merupakan bagian dari *Artificial Intelligence* yang memungkinkan sistem belajar dari data untuk melakukan prediksi atau deteksi. Dalam deteksi citra penyakit daun tanaman, *machine learning* dapat digunakan untuk membedakan citra daun sehat dan citra daun yang terkena penyakit berdasarkan fitur tertentu, seperti warna, tekstur, bentuk, dan pola bercak.

Beberapa metode *machine learning* yang dapat digunakan dalam deteksi citra antara lain *Support Vector Machine*, *K-Nearest Neighbor*, *Decision Tree*, *Random Forest*, dan *Naive Bayes*. Metode *machine learning* konvensional umumnya memerlukan proses ekstraksi fitur manual sebelum proses deteksi dilakukan. Berbeda dengan metode tersebut, CNN mampu mempelajari fitur visual secara otomatis dari citra, sehingga lebih sesuai untuk data citra yang memiliki pola visual kompleks [13], [19].

3. Deep learning

Deep learning merupakan pengembangan dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis banyak untuk mempelajari representasi fitur dari data. Pada pengolahan citra, *Deep learning* mampu mempelajari pola visual secara otomatis tanpa memerlukan ekstraksi fitur manual. Kemampuan tersebut membuat *Deep learning* banyak digunakan dalam deteksi citra, termasuk pada deteksi penyakit daun tanaman [3], [4].

Dalam penelitian ini, *Deep learning* digunakan sebagai pendekatan utama untuk membangun model deteksi penyakit daun tanaman berbasis citra digital. Model *Deep learning* yang digunakan adalah *Convolutional Neural Network* dengan tiga arsitektur, yaitu VGG16, ResNet50, dan MobileNetV2. Ketiga arsitektur tersebut dibandingkan untuk mengetahui performa deteksi berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

4. Pengolahan Citra Digital

Pengolahan citra digital merupakan proses pemrosesan gambar menggunakan komputer untuk memperoleh informasi tertentu dari citra. Dalam deteksi penyakit daun tanaman, pengolahan citra digital digunakan untuk menyiapkan citra agar dapat diproses oleh model deteksi. Tahapan ini dapat meliputi penyesuaian ukuran citra, normalisasi nilai piksel, augmentasi data, dan pembagian dataset [6], [10].

Pada penelitian ini, citra digital yang digunakan berupa gambar daun tanaman yang memiliki label kelas penyakit dan kelas daun sehat. Pengolahan citra dilakukan agar data memiliki ukuran dan format yang seragam sebelum dimasukkan ke dalam model CNN. Dengan *preprocessing* yang tepat, tahap *preprocessing* meliputi:

- a. Akuisisi citra
- b. *Resize* gambar
- c. Normalisasi data
- d. Augmentasi data
- e. Input ke model CNN

5. *Convolutional Neural Network* (CNN)

Convolutional Neural Network merupakan salah satu metode *Deep learning* yang dirancang untuk memproses data berbentuk citra. CNN bekerja dengan mengekstraksi fitur visual melalui *convolution layer*, menyederhanakan fitur melalui *pooling layer*, dan melakukan deteksi melalui *fully connected layer*. Keunggulan utama CNN adalah kemampuannya dalam mempelajari fitur secara otomatis dari citra tanpa memerlukan proses ekstraksi fitur manual [4], [6].

Dalam identifikasi penyakit tanaman, CNN banyak digunakan karena mampu mengenali pola visual pada daun, seperti warna, bercak, tekstur, dan bentuk kerusakan. Pada penelitian ini, CNN menjadi metode utama yang digunakan untuk membangun model deteksi penyakit daun tanaman. Arsitektur CNN yang dibandingkan adalah VGG16, ResNet50, dan MobileNetV2.

a. Arsitektur VGG16

VGG16 merupakan arsitektur CNN yang dikembangkan oleh Simonyan dan Zisserman. Arsitektur ini menggunakan susunan lapisan konvolusi dengan ukuran kernel kecil, yaitu 3×3 , dan memiliki 16 lapisan berbobot. VGG16 dikenal sebagai arsitektur yang sederhana, terstruktur, dan banyak digunakan dalam berbagai tugas deteksi citra [7].

Pada penelitian ini, VGG16 digunakan sebagai salah satu arsitektur CNN yang dibandingkan. Penggunaan VGG16 bertujuan untuk mengetahui performa arsitektur tersebut dalam deteksi penyakit daun tanaman berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, penelitian terkait deteksi penyakit daun tanaman juga menunjukkan bahwa VGG16 dapat digunakan sebagai salah satu model *Deep learning* yang dibandingkan dalam deteksi citra penyakit daun [11].

b. Arsitektur ResNet50

ResNet50 merupakan arsitektur CNN yang menggunakan konsep residual learning. Arsitektur ini dikembangkan untuk membantu proses pelatihan jaringan yang lebih dalam. ResNet menggunakan residual connection atau skip connection, yaitu mekanisme yang memungkinkan informasi dari lapisan sebelumnya diteruskan secara langsung ke lapisan berikutnya [8].

Pada penelitian ini, ResNet50 digunakan sebagai salah satu arsitektur CNN yang dibandingkan. Penggunaan ResNet50 bertujuan untuk mengetahui kemampuan arsitektur jaringan yang lebih dalam dalam melakukan deteksi penyakit daun tanaman berbasis citra digital. Beberapa penelitian deteksi penyakit daun tanaman juga menggunakan ResNet50 sebagai model utama maupun sebagai model pembanding karena kemampuannya dalam mempelajari fitur citra secara mendalam [5], [12], [15].

c. Arsitektur MobileNetV2

MobileNetV2 merupakan arsitektur CNN yang dirancang agar lebih ringan dibandingkan beberapa arsitektur CNN besar. Arsitektur ini menggunakan *inverted residual*, linear bottleneck, dan *depthwise separable convolution*. Konsep tersebut membuat MobileNetV2 dapat mengurangi jumlah operasi komputasi tanpa menghilangkan kemampuan model dalam mempelajari fitur citra [9].

Pada penelitian ini, MobileNetV2 digunakan sebagai salah satu arsitektur CNN yang dibandingkan dengan VGG16 dan ResNet50. Penggunaan MobileNetV2 bertujuan untuk mengetahui performa deteksi model dalam mengenali penyakit daun tanaman berdasarkan citra digital. Penelitian sebelumnya juga menunjukkan bahwa

MobileNetV2 banyak digunakan dalam deteksi penyakit daun tanaman, baik sebagai model tunggal maupun sebagai bagian dari pendekatan ensemble atau *transfer learning* [12], [15].

6. *Transfer learning*

Transfer learning merupakan teknik pemanfaatan model yang telah dilatih sebelumnya pada dataset besar untuk menyelesaikan permasalahan baru. Dalam deteksi citra, model *pre-trained* telah mempelajari fitur dasar seperti garis, tepi, bentuk, tekstur, dan pola visual. Fitur tersebut dapat dimanfaatkan kembali untuk deteksi penyakit daun tanaman dengan menyesuaikan lapisan akhir model sesuai jumlah kelas yang digunakan [5], [6].

Pada penelitian ini, *transfer learning* digunakan pada arsitektur VGG16, ResNet50, dan MobileNetV2. Pendekatan ini dipilih karena dapat membantu proses pelatihan model dan mendukung penerapan CNN pada dataset citra penyakit daun tanaman. Beberapa penelitian sebelumnya juga menggunakan *transfer learning* untuk deteksi penyakit daun tanaman dengan model seperti ResNet50, MobileNetV2, dan EfficientNetB0 [5], [12], [15].

7. Dataset Citra Penyakit Daun Tanaman

Dataset merupakan kumpulan data yang digunakan dalam proses pelatihan, validasi, dan pengujian model. Dalam penelitian deteksi penyakit daun tanaman, dataset berisi citra daun yang telah diberi label sesuai jenis tanaman dan kelas penyakitnya. Label pada dataset digunakan sebagai acuan agar model dapat mempelajari perbedaan antar kelas penyakit [10], [14].

Pada penelitian ini, dataset yang digunakan berupa citra daun tanaman yang terdiri dari beberapa kelas penyakit dan kelas daun sehat. Dataset tersebut perlu melalui proses seleksi dan *preprocessing* agar citra memiliki kualitas dan format yang sesuai untuk proses pelatihan model CNN. Dataset citra penyakit daun tanaman banyak digunakan dalam penelitian *Deep learning* karena memungkinkan model mempelajari pola visual dari data berlabel [4].

Dalam pengumpulan dataset penyakit tanaman berbasis citra, tidak terdapat standar universal yang menetapkan jumlah megapiksel minimum kamera. Literatur lebih menekankan kualitas dan keterwakilan citra, seperti objek daun dan gejala penyakit terlihat jelas, citra berada dalam kondisi fokus, pencahayaan memadai, serta terdapat variasi sudut, latar belakang, orientasi, dan kondisi pengambilan. Penelitian terdahulu menunjukkan bahwa citra penyakit daun yang dikumpulkan pada kondisi lapangan dapat memiliki variasi pencahayaan, sudut pengambilan, permukaan, dan noise agar dataset lebih merepresentasikan kondisi nyata [20], [21].

Citra yang diperoleh menggunakan perangkat bergerak juga dapat dipengaruhi oleh pencahayaan, sudut pengambilan, latar belakang, dan karakteristik kamera. Oleh karena itu, kualitas dataset tidak hanya ditentukan oleh resolusi kamera, tetapi juga oleh prosedur pengambilan citra, ketajaman objek, keterbacaan gejala, dan variasi kondisi lapangan [22].

8. *Preprocessing Data*

Preprocessing data merupakan tahap awal untuk menyiapkan citra sebelum digunakan dalam proses pelatihan model. *Preprocessing* diperlukan agar citra memiliki ukuran, format, dan nilai piksel yang seragam sehingga dapat diproses oleh model *Deep learning*. Tahapan *preprocessing* pada deteksi citra umumnya meliputi *resize citra*, normalisasi nilai piksel, augmentasi data, serta pembagian dataset menjadi data latih, validasi, dan uji [6], [10].

Pada penelitian ini, *preprocessing* dilakukan dengan mengubah ukuran citra menjadi 224×224 piksel, melakukan normalisasi nilai piksel, serta menerapkan augmentasi data seperti rotasi, flip, dan zoom. Tahapan ini bertujuan untuk meningkatkan variasi data dan mengurangi risiko *overfitting* pada proses pelatihan model [15].

9. Pembagian Dataset dan Fungsi Data *Validation*

Dalam pengembangan model *machine learning*, dataset perlu dipisahkan agar proses pembelajaran, pemilihan model, dan evaluasi akhir tidak menggunakan data yang sama. Secara umum, dataset dapat dikelompokkan menjadi data pengembangan model dan data pengujian. Data pengembangan selanjutnya dapat dibagi menjadi data *Training* dan data *validation*. Data *Training* digunakan untuk memperbarui bobot model, sedangkan data *validation* digunakan untuk mengevaluasi performa sementara selama proses pelatihan dan membantu pemilihan konfigurasi atau *checkpoint* model. Data *testing* dipisahkan dari proses pengembangan dan digunakan untuk memberikan estimasi performa akhir pada data yang belum digunakan dalam pelatihan maupun pemilihan model [23], [24], [25].

Penggunaan data *validation* diperlukan agar pemantauan performa model tidak dilakukan menggunakan data *testing*. Apabila data *testing* ikut digunakan untuk menentukan model, epoch, atau parameter yang dipilih, hasil evaluasi akhir dapat mengalami selection bias dan tidak lagi mencerminkan pengujian yang independen [24].

Pada implementasi Keras, data yang diberikan melalui parameter *validation_data* digunakan untuk menghitung nilai *Loss* dan metrik pada akhir setiap epoch, tetapi data tersebut tidak digunakan untuk melatih atau memperbarui bobot model. Dengan demikian, *validation* berperan sebagai bagian dari proses pengembangan model, sedangkan *testing* tetap menjadi

dasar evaluasi akhir. Dokumentasi Keras juga menjelaskan bahwa *validation_data* dievaluasi setiap akhir epoch tanpa digunakan untuk *Training*.

10. Kriteria Visual Penyakit Daun Tanaman

Kriteria visual penyakit daun tanaman merupakan gejala yang tampak pada permukaan daun dan dapat digunakan sebagai dasar pengenalan penyakit. Gejala tersebut dapat berupa perubahan warna, munculnya bercak, perubahan tekstur permukaan, daun mengering, daun berlubang, daun menggulung, atau perubahan bentuk daun. Informasi visual tersebut menjadi dasar dalam proses pengenalan penyakit daun berbasis citra digital [4], [10].

Dalam pendekatan berbasis CNN, kriteria visual tersebut tidak ditentukan secara manual oleh sistem. Model CNN akan mempelajari pola visual dari citra selama proses pelatihan. Namun, penjelasan kriteria visual tetap diperlukan agar ruang lingkup deteksi penyakit daun tanaman dapat dipahami secara jelas.[16]

a. *Healthy*.


Daun sehat digunakan sebagai kelas kontrol dan secara operasional ditandai oleh warna hijau yang relatif merata, bentuk daun normal, serta tidak menunjukkan lapisan putih seperti tepung, pola mosaik atau bercak klorotik, maupun gejala daun menggulung. Karakteristik sehat daun melon ditunjukkan pada Gambar 2 dibawah ini [26].



Gambar 2 Daun melon sehat berdasarkan literatur

b. *Powdery Mildew*

Powdery Mildew pada melon berkaitan dengan infeksi jamur yang menimbulkan bercak atau lapisan putih seperti tepung pada permukaan daun. Infeksi dapat berkembang pada jaringan daun dan memengaruhi struktur daun, kandungan klorofil, proses fotosintesis, kualitas, serta hasil tanaman melon. Karakteristik sehat daun melon ditunjukkan pada Gambar 3 dibawah ini [27], [28].



Gambar 3 Gejala *Powdery Mildew* pada daun melon berdasarkan literatur

c. *Cucumber Mosaic Virus*

Tanaman melon yang terinfeksi *Cucumber Mosaic Virus* dapat menunjukkan bercak klorotik dan pola mosaik sistemik pada daun. Gejala tersebut dapat disertai perubahan bentuk daun dan gangguan pertumbuhan, sedangkan kepastian penyebab virus memerlukan pengujian serologis atau molekuler. Karakteristik sehat daun melon ditunjukkan pada Gambar 4 dibawah ini [29], [30].



Gambar 4 Gejala *Cucumber Mosaic Virus* pada daun melon

d. *Leaf Curl Disease*

Penyakit daun keriting pada melon dapat menunjukkan gejala awal berupa bercak kuning, kemudian berkembang menjadi penebalan tulang daun, daun menggulung atau keriting, serta pertumbuhan tanaman yang terhambat. Penelitian pada melon di Yogyakarta mengidentifikasi Begomovirus sebagai penyebab penyakit daun keriting, sedangkan penelitian lain melaporkan klorosis tidak merata dan leaf curling pada infeksi Melon chlorotic leaf curl virus. Karakteristik sehat daun melon ditunjukkan pada Gambar 5 dibawah ini [31].



Gambar 5 Tanaman melon tanpa gejala dan dengan gejala Leaf Curl Disease

Tabel 2 Tabel kriteria visual penyakit daun tanaman

No	penyakit	Ciri visual
1	<i>Healthy</i>	Hijau normal
2	<i>Powdery Mildew</i>	Lapisan putih seperti tepung
3	<i>Cucumber Mosaic Virus</i>	Daun menguning dan mosaik
4	<i>Leaf Curl Disease</i>	Daun menggulung

11. *Confusion matrix*

Confusion matrix merupakan tabel evaluasi yang digunakan untuk membandingkan hasil prediksi model dengan label sebenarnya. Dalam deteksi, *confusion matrix* digunakan sebagai dasar untuk menghitung metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*. *Confusion matrix* banyak digunakan dalam evaluasi performa deteksi karena mampu menunjukkan jumlah prediksi benar dan salah pada masing-masing kelas [32].

Fungsi masing-masing metrik:

- a. *Accuracy*
 - 1) Mengukur persentase prediksi yang benar dari seluruh data.
 - 2) Cocok jika jumlah data setiap kelas seimbang.
- b. *Precision*
 - 1) Mengukur ketepatan prediksi suatu kelas.
 - 2) Semakin tinggi *precision*, semakin sedikit prediksi positif yang salah (*False Positive*).
- c. *Recall*
 - 1) Mengukur kemampuan model menemukan seluruh data yang benar pada suatu kelas.
 - 2) Semakin tinggi *recall*, semakin sedikit data positif yang terlewat (*False Negative*).
- d. *F1-score*
 - 1) Merupakan rata-rata harmonik antara *precision* dan *recall*.
 - 2) Sangat berguna jika ingin melihat keseimbangan antara *precision* dan *recall*.

Confusion matrix diperoleh dari hasil pengujian model terhadap data *testing*. Pada tahap pengujian, model menghasilkan prediksi kelas untuk setiap citra daun tanaman. Hasil prediksi tersebut kemudian dibandingkan dengan label sebenarnya pada data *testing*. Dari perbandingan tersebut diperoleh jumlah prediksi yang benar dan salah, yang selanjutnya dikelompokkan ke dalam komponen *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

Keterangan komponen *confusion matrix* adalah sebagai berikut:

- a. TP atau *True Positive* adalah jumlah data positif yang berhasil diprediksi benar sebagai positif.
- b. TN atau *True Negative* adalah jumlah data negatif yang berhasil diprediksi benar sebagai negatif.
- c. FP atau *False Positive* adalah jumlah data negatif yang salah diprediksi sebagai positif.
- d. FN atau *False Negative* adalah jumlah data positif yang salah diprediksi sebagai negatif.

12. Evaluasi Performa Model

Evaluasi performa model dilakukan untuk mengetahui kemampuan model dalam melakukan deteksi penyakit daun tanaman. Dalam penelitian ini, evaluasi performa model dibatasi pada metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Keempat metrik tersebut digunakan untuk membandingkan performa model deteksi berbasis CNN dengan arsitektur VGG16, ResNet50, dan MobileNetV2 [32].

a. *Accuracy*

Accuracy merupakan metrik evaluasi yang digunakan untuk mengukur persentase jumlah prediksi benar terhadap seluruh data pengujian. Metrik ini memberikan gambaran umum mengenai kemampuan model dalam melakukan deteksi. Rumus *Accuracy* adalah sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Accuracy cocok digunakan ketika jumlah data pada setiap kelas relatif seimbang. Namun, apabila dataset memiliki ketidakseimbangan jumlah data antar kelas, *Accuracy* perlu didukung oleh metrik lain seperti *precision*, *recall*, dan *F1-score*.

b. *Precision*

Precision merupakan metrik yang digunakan untuk mengukur ketepatan model ketika memberikan prediksi pada suatu kelas. *Precision* menunjukkan perbandingan antara jumlah prediksi positif yang benar dengan seluruh data yang diprediksi positif oleh model. Rumus *precision* adalah sebagai berikut:

$$Precision = \frac{TP}{TP + FP}$$

Precision yang tinggi menunjukkan bahwa model memiliki tingkat kesalahan yang rendah dalam memberikan prediksi positif.

c. *Recall*

Recall merupakan metrik yang digunakan untuk mengukur kemampuan model dalam menemukan seluruh data positif yang sebenarnya. *Recall* menunjukkan perbandingan antara jumlah data positif yang berhasil diprediksi benar dengan seluruh data positif yang sebenarnya. Rumus *recall* adalah sebagai berikut:

$$Recall = \frac{TP}{TP + FN}$$

Recall yang tinggi menunjukkan bahwa model mampu mendeteksi sebagian besar data positif dan memiliki tingkat kegagalan deteksi yang rendah.

d. *F1-score*

F1-score merupakan metrik evaluasi yang menggabungkan *precision* dan *recall* dalam satu nilai. Metrik ini digunakan untuk mengetahui keseimbangan antara ketepatan prediksi dan kemampuan model dalam menemukan data positif. Rumus *F1-score* adalah sebagai berikut:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

F1-score sangat berguna ketika dataset memiliki distribusi kelas yang tidak seimbang, karena metrik ini mempertimbangkan *precision* dan *recall* secara bersamaan.