

Klasifikasi Multi Penyakit Tanaman Pepaya Berdasarkan Citra Daun Berbasis Deep Learning Menggunakan Convolutional Neural Network (CNN)

Heri Wahyudi, Abdul Fadlil, Herman

Informatika, Universitas Ahmad Dahlan, Yogyakarta

Email: 2536083034@webmail.uad.ac.id, abdul.fadlil@uad.ac.id, hermankaha@uad.ac.id

Diajukan: 11-08-2026 Direvisi: 02-09-2026	Disetujui: 03-09-2026 Diterbitkan: 30-09-2026
<i>Abstract. Papaya leaf diseases such as Anthracnose, Bacterial Spot, Curl, and Ring Spot can significantly reduce productivity and crop yield quality. Limitations of conventional methods relying on manual visual observation make the disease identification process inconsistent, time-consuming, and difficult to apply on a large agricultural scale. This study aims to develop a Convolutional Neural Network (CNN)-based deep learning model to accurately classify five categories of papaya leaf conditions. The methodology utilizes the BDPapayaLeaf dataset containing 2,159 original images, expanded to 6,477 images using data augmentation techniques. The model was trained using a 70:15:15 data split (train, validation, test) leveraging transfer learning, the Adam optimizer, and an early stopping mechanism. The test results show that the proposed PapayaLeafCNN model achieved an overall accuracy of 84.66% and a weighted average F1-score of 84.82% on the test data. Class-level analysis indicated the best performance on the Healthy class with an F1-score of 94.29%, while the Bacterial Spot recorded the lowest performance (76.54%) due to a high rate of prediction overlap with the Curl class. Overall, the proposed CNN model performs multi-disease classification of papaya leaves well, although specific strategies are still needed to classify diseases with high visual similarity.</i> Keywords: CNN, data augmentation, deep learning, disease classification , papaya leaves <i>Abstrak. Penyakit pada tanaman pepaya seperti Anthracnose, Bacterial Spot, Curl, dan Ring Spot dapat menurunkan produktivitas dan kualitas hasil panen secara signifikan. Keterbatasan metode konvensional yang mengandalkan pengamatan visual secara manual menyebabkan proses identifikasi penyakit menjadi tidak konsisten, memakan waktu lama, dan sulit diterapkan pada skala lahan pertanian yang luas. Penelitian ini bertujuan untuk mengembangkan model deep learning berbasis Convolutional Neural Network (CNN) guna mengklasifikasikan lima kategori kondisi daun pepaya secara akurat. Metodologi yang digunakan meliputi pemanfaatan dataset BDPapayaLeaf yang berisi 2.159 citra asli, yang kemudian diekspansi menjadi 6.477 citra menggunakan teknik augmentasi data. Model dilatih menggunakan pembagian data 70:15:15 (latih, validasi, uji) dengan memanfaatkan metode transfer learning, optimizer Adam, dan mekanisme early stopping. Hasil pengujian menunjukkan bahwa model PapayaLeafCNN yang diusulkan berhasil mencapai akurasi keseluruhan sebesar 84,66% dan weighted average F1-score sebesar 84,82% pada data uji. Analisis per kelas menunjukkan performa tertinggi pada kelas daun sehat (Healthy) dengan F1-score 94,29%, sementara kelas Bacterial Spot mencatatkan performa terendah (76,54%) akibat tingginya tingkat kesalahan prediksi yang tumpang tindih dengan kelas Curl. Secara keseluruhan, model CNN yang diusulkan mampu melakukan klasifikasi multi-penyakit daun pepaya dengan baik, meski ke depannya tetap diperlukan strategi khusus untuk mengklasifikasikan penyakit dengan kemiripan visual yang tinggi.</i> Kata Kunci: augmentasi data, CNN, daun pepaya, deep learning, klasifikasi penyakit	

1. Pendahuluan

Pepaya (*Carica papaya* L.) merupakan salah satu komoditas hortikultura unggulan yang memiliki nilai ekonomi dan gizi tinggi. Buah pepaya kaya akan vitamin C, vitamin A, enzim papain, dan antioksidan yang bermanfaat bagi kesehatan manusia. Indonesia sebagai salah satu produsen pepaya terbesar di dunia memiliki potensi yang sangat besar untuk mengembangkan budidaya pepaya secara komersial. Namun demikian, produktivitas tanaman pepaya seringkali terhambat oleh berbagai jenis penyakit yang menyerang bagian daun, batang, akar, maupun buah (Mir dkk., 2024). Serangan penyakit tidak hanya menyebabkan penurunan hasil panen secara kuantitatif, tetapi juga menurunkan kualitas produk yang berdampak pada kerugian ekonomi yang signifikan bagi para petani.

Berbagai penyakit tanaman pepaya yang teridentifikasi melalui gejala pada daun telah menjadi ancaman utama dalam budidaya pepaya, di antaranya Anthracnose, Bacterial Spot, Curl, Ring Spot, dan kondisi daun sehat (Healthy). Masing-masing penyakit menunjukkan gejala visual yang khas pada citra daun, seperti mosaik kuning, bercak putih tepung, bercak coklat konsentris, nekrosis jaringan, dan lesi berair. Identifikasi penyakit yang akurat merupakan langkah pertama yang krusial dalam manajemen penyakit tanaman, karena intervensi dini dapat mencegah penyebaran yang lebih luas dan meminimalkan kerugian panen. Sayangnya, metode konvensional yang mengandalkan pengamatan visual oleh pakar pertanian seringkali tidak konsisten, memakan waktu, dan tidak skalabel untuk penerapan di lahan pertanian yang luas (Suryavanshi dkk., 2024).

Penelitian-penelitian terdahulu dalam bidang **klasifikasi penyakit** tanaman berbasis deep learning umumnya berfokus **pada satu atau dua jenis penyakit saja**, sehingga cakupan klasifikasi multi-penyakit yang komprehensif masih terbatas (Kamilaris & Prenafeta-Boldú, 2022; Sofuoglu dkk., 2024; Brahimi dkk., 2023). Beberapa penelitian yang mengkaji penyakit tanaman pepaya melalui identifikasi daun secara spesifik juga masih terbatas dalam jumlah kelas penyakit yang ditangani, ukuran dataset yang digunakan, maupun keberagaman kondisi pengambilan citra (Mir dkk., 2024). Kesenjangan penelitian ini menjadi semakin relevan mengingat pepaya merupakan komoditas hortikultura strategis yang membutuhkan sistem deteksi dini yang akurat, cepat, dan dapat diandalkan untuk mendukung skala budidaya yang luas. Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model deep learning berbasis Convolutional Neural Network (CNN) yang mampu mengklasifikasikan lima kondisi daun pepaya dengan akurasi tinggi, sekaligus mengevaluasi pola kesalahan klasifikasi pada kelas-kelas dengan kemiripan visual tinggi sebagai dasar perbaikan model di masa depan.

2. Tinjauan Pustaka

2.1 Metode Machine Learning Konvensional untuk Deteksi Penyakit Tanaman

Sebelum era deep learning, deteksi penyakit tanaman berbasis citra mengandalkan metode machine learning konvensional yang memerlukan rekayasa fitur (feature engineering) secara manual. Support Vector Machine (SVM) merupakan salah satu algoritma yang paling banyak digunakan, di mana fitur warna, tekstur, dan bentuk diekstraksi secara manual kemudian diklasifikasikan menggunakan hyperplane optimal di ruang fitur berdimensi tinggi (Shoaib dkk., 2023). K-Nearest Neighbor (KNN) juga banyak diterapkan untuk klasifikasi citra daun berdasarkan kemiripan fitur dengan sampel terlatih (Xiong dkk., 2024). Selain itu, Random Forest dan Decision Tree digunakan untuk mengklasifikasikan penyakit tanaman berdasarkan fitur

warna HSV dan GLCM (Gray-Level Co-occurrence Matrix) yang diekstraksi dari citra (Hurtado dkk., 2023). Algoritma Naive Bayes diterapkan dalam sistem pengenalan gejala penyakit daun dengan menggunakan fitur statistik citra sebagai probabilitas kondisional (Ahmed dkk., 2023).

Meskipun pendekatan-pendekatan tersebut memberikan hasil yang cukup menjanjikan pada dataset kecil dengan kondisi terkontrol, keterbatasan utamanya terletak pada ketergantungan terhadap fitur yang dirancang secara manual, sensitivitas tinggi terhadap variasi pencahayaan dan sudut pandang pengambilan citra, serta ketidakmampuan untuk menangani variasi intra-kelas yang besar pada kondisi lapangan nyata (Kaur dkk., 2024).

2.2 Arsitektur Convolutional Neural Network untuk Klasifikasi Penyakit Tanaman

Perkembangan teknologi deep learning membawa perubahan paradigma yang signifikan dalam bidang klasifikasi penyakit tanaman. Arsitektur CNN awal seperti AlexNet menjadi pelopor dalam pemanfaatan deep learning untuk klasifikasi citra penyakit tanaman skala besar yang kini banyak dibahas dalam literatur modern (Isty dkk., 2023). Selanjutnya, VGGNet yang memiliki arsitektur dalam dengan filter konvolusional berukuran kecil (3×3) secara konsisten mampu menangkap representasi fitur yang lebih kaya dan hierarkis dibandingkan metode konvensional (Nikith dkk., 2023). Arsitektur ResNet dengan mekanisme skip connection memecahkan masalah vanishing gradient pada jaringan yang sangat dalam dan terbukti unggul dalam klasifikasi penyakit daun pada berbagai tanaman (Madhurya & Jubilson, 2025).

Arsitektur Inception (GoogLeNet) memperkenalkan modul inception yang mampu menangkap fitur pada berbagai skala secara simultan, sehingga efektif untuk mendeteksi lesi penyakit yang bervariasi ukurannya (Saad & Salman, 2025). MobileNet dan MobileNetV2 dirancang untuk efisiensi komputasi menggunakan depthwise separable convolution, menjadikannya pilihan populer untuk implementasi sistem deteksi penyakit berbasis perangkat mobile (Ashtagi dkk., 2025). DenseNet dengan koneksi padat antar lapisan menunjukkan kemampuan yang baik dalam mengekstraksi fitur multi-skala untuk klasifikasi penyakit tanaman dengan dataset terbatas (Parashar dkk., 2024). Adapun arsitektur EfficientNet menjadi terobosan penting karena berhasil mencapai keseimbangan optimal antara akurasi dan efisiensi komputasi melalui pendekatan compound scaling, yaitu penskalaan simultan pada dimensi kedalaman jaringan, lebar lapisan, dan resolusi citra input (Vishnoi dkk., 2023). Meskipun model-model deep learning tersebut telah menunjukkan akurasi yang tinggi dalam tugas klasifikasi citra tanaman, kompleksitas arsitektur yang tinggi serta kebutuhan komputasi yang besar tetap menjadi pertimbangan penting dalam pemilihan model untuk implementasi praktis.

2.3 Tren Penelitian Terkini dan Penelitian Terkait pada Tanaman Pepaya

Tren penelitian dalam beberapa tahun terakhir (2023-2025) menunjukkan pergeseran ke arah implementasi model CNN ringan yang dapat dijalankan secara real-time pada perangkat mobile (Chen dkk., 2025; Rahman dkk., 2024). Di samping itu, teknik augmentasi data tingkat lanjut terbukti menjadi solusi krusial dalam mengatasi ketidakseimbangan kelas pada dataset citra pertanian (Hasan dkk., 2023). Pendekatan transfer learning juga semakin diandalkan untuk mendeteksi penyakit spesifik pada tanaman tropis, seperti pepaya dan mangga, guna mencapai akurasi yang optimal (Sharma dkk., 2024). Integrasi antara Internet of Things (IoT) dan deep learning bahkan mulai dieksplorasi secara luas untuk pemantauan penyakit daun tanaman secara otomatis di lingkungan pertanian cerdas (Kim & Lee, 2025).


Secara khusus pada tanaman pepaya, Mir dkk. (2024) mengusulkan model hibrida yang mengintegrasikan CNN dan Random Forest untuk meningkatkan akurasi klasifikasi penyakit

daun pepaya. Mustofa dkk. (2024) menyediakan dataset BDPapayaLeaf sebagai basis data citra publik untuk keperluan deteksi dan klasifikasi penyakit pepaya. Sementara itu, Banarase dan Shirbahadurkar (2024) menunjukkan bahwa fusi CNN dengan transfer learning dapat meningkatkan presisi diagnosis penyakit daun pepaya. Berdasarkan tinjauan pustaka di atas, dapat disimpulkan bahwa penelitian klasifikasi penyakit pepaya berbasis deep learning yang komprehensif untuk lima kategori kondisi daun sekaligus, lengkap dengan analisis kesalahan klasifikasi antar-kelas, masih menjadi gap penelitian yang relevan untuk dieksplorasi lebih lanjut.

3. Metode Penelitian

Penelitian ini menggunakan pendekatan eksperimen dalam pengembangan dan evaluasi model deep learning untuk klasifikasi penyakit pepaya berbasis citra daun. Metodologi penelitian dirancang secara sistematis dalam beberapa tahapan utama yang saling berkesinambungan, mulai dari akuisisi dan kurasi data, pra-pemrosesan citra, perancangan dan pelatihan model, hingga evaluasi performa secara komprehensif.

3.1 Kerangka Kerja Penelitian



Gambar 1. Kerangka Kerja Penelitian Klasifikasi Multi-Penyakit Daun Pepaya

Kerangka kerja penelitian ini mengadopsi alur pipeline yang telah diadaptasi untuk klasifikasi multi-penyakit tanaman dengan pendekatan deep learning, sebagaimana ditunjukkan pada Gambar 1. Tahapan kerangka kerja penelitian dijabarkan sebagai berikut:

1. **Tahap Awal (Input).** Menemukan dan merumuskan batasan masalah utama terkait inkonsistensi identifikasi visual penyakit tanaman serta keterbatasan metode machine learning konvensional di lapangan, dilanjutkan dengan studi literatur mengenai arsitektur deep learning untuk klasifikasi penyakit tanaman, khususnya pepaya.
2. **Pengumpulan Dataset Citra.** Menggunakan total 2.159 citra asli daun pepaya dari dataset BDPapayaLeaf yang mencakup 5 kategori kondisi daun, yaitu Daun Sehat (Healthy), Anthracnose, Bacterial Spot, Curl, dan Ring Spot.
3. **Pra-pemrosesan Data (Preprocessing).** Meliputi seleksi dan pembersihan citra yang tidak berkualitas atau buram; resize dimensi citra ke standar 320×320 piksel; normalisasi nilai piksel ke rentang $[0, 1]$ menggunakan statistik mean dan standar deviasi dataset ImageNet; serta augmentasi data secara ekstensif sebesar tiga kali lipat (rotasi acak $\pm 30^\circ$, horizontal & vertical flip, perubahan kecerahan, kontras, Gaussian noise, dan random erasing) sehingga jumlah total data meningkat menjadi 6.477 citra.
4. **Pembagian Dataset.** Dataset dibagi dengan rasio 70% data latih, 15% data validasi, dan 15% data uji. Data uji sebanyak 326 citra diisolasi murni dan tidak dilibatkan dalam proses training maupun validasi untuk menjaga objektivitas evaluasi akhir.
5. **Perancangan Model CNN (Modeling).** Model diinisialisasi menggunakan teknik transfer learning dengan bobot pra-latih (pre-trained) dari dataset ImageNet yang kemudian di-fine-tuning. Komponen regulasi yang diterapkan meliputi Dropout (rate 0,3), L2 weight decay, dan label smoothing untuk mencegah overfitting.
6. **Proses Training & Validasi Model.** Menggunakan optimizer Adam dengan learning rate awal 1×10^{-4} yang dikombinasikan dengan cosine annealing scheduler, ukuran batch size 32, dan maksimum hingga 80 epoch. Mekanisme early stopping diterapkan berdasarkan pemantauan nilai validation loss; selama validation loss masih membaik, proses training berlanjut, dan dihentikan ketika nilai tersebut tidak lagi membaik.
7. **Proses Testing.** Model terlatih diuji menggunakan 326 citra data uji yang telah diisolasi sejak tahap pembagian dataset untuk memastikan hasil evaluasi mencerminkan kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya.
8. **Evaluasi dan Analisis (Output).** Mencakup pembuatan confusion matrix untuk menganalisis detail ketepatan prediksi serta pengukuran kinerja akhir model berdasarkan nilai Accuracy, Precision, Recall, dan F1-Score, baik dalam versi macro maupun weighted average.

3.2 Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 2.159 citra daun pepaya yang dikumpulkan dari BDPapayaLeaf (Mustofa dkk., 2024), terbagi ke dalam lima kelas kondisi daun. Distribusi jumlah citra asli dan hasil augmentasi pada masing-masing kelas ditunjukkan pada Tabel 1. Dari total 2.159 citra asli, setelah dilakukan augmentasi data dengan faktor tiga kali lipat, diperoleh total 6.477 citra yang digunakan dalam proses pelatihan. Pembagian data dilakukan dengan rasio 70:15:15 untuk data latih, data validasi, dan data uji secara berturut-turut, dengan stratifikasi pada tingkat kelas untuk menjaga keseimbangan distribusi di setiap subset.

Tabel 1. Distribusi Dataset Citra Daun Pepaya

<i>No</i>	<i>Kelas</i>	<i>Citra Asli</i>	<i>Citra Augmentasi</i>
1	Daun Sehat (Healthy)	228	684
2	Anthrachnose	355	1.065
3	Bacterial Spot	458	1.374
4	Curl	585	1.755
5	Ring Spot	533	1.599
Total	-	2.159	6.477

3.3 Konfigurasi Pelatihan Model

Implementasi model PapayaLeafCNN menggunakan konfigurasi parameter yang dioptimalkan untuk tugas klasifikasi citra daun, sebagaimana dirangkum pada Tabel 2.

Tabel 2. Konfigurasi Parameter Pelatihan Model PapayaLeafCNN

<i>Parameter</i>	<i>Nilai</i>	<i>Keterangan</i>
Metode Inisialisasi	Transfer Learning (ImageNet)	Bobot pra-latih yang di-fine-tuning
Optimizer	Adam	Adaptive learning rate optimization
Learning Rate Awal	1×10^{-4}	Dikombinasikan dengan cosine annealing scheduler
Batch Size	32	Ukuran batch pelatihan
Maksimum Epoch	80	Dibatasi oleh mekanisme early stopping
Dropout Rate	0,3	Regulasi untuk mencegah overfitting
Regularisasi	L2 weight decay & label smoothing	Regulasi tambahan pada bobot model
Ukuran Input Citra	320×320 piksel	Hasil tahap resize pada preprocessing
Kriteria Early Stopping	Validation loss	Pelatihan dihentikan saat val. loss tidak membaik

Eksperimen dijalankan pada sistem dengan GPU NVIDIA RTX 3050 (4 GB VRAM), prosesor Intel Core i7-12700H, RAM 16 GB, dan sistem operasi Windows. Implementasi dilakukan menggunakan Python 3.9 dengan framework Google Colab untuk pelatihan model deep learning.

3.4 Metrik Evaluasi

Evaluasi performa model dilakukan menggunakan empat metrik utama, yaitu Accuracy, Precision, Recall, dan F1-Score, baik dalam bentuk macro average maupun weighted average, sebagaimana dirangkum pada Tabel 3.

Tabel 3. Metrik Evaluasi Model


<i>Metrik</i>	<i>Persamaan</i>	<i>Deskripsi</i>
Akurasi	$(TP+TN) / (TP+TN+FP+FN)$	Proporsi prediksi yang benar secara keseluruhan
Presisi	$TP / (TP+FP)$	Proporsi prediksi positif yang benar untuk suatu kelas
Recall	$TP / (TP+FN)$	Proporsi sampel aktual suatu kelas yang berhasil diidentifikasi
F1-Score	$2 \times (\text{Presisi} \times \text{Recall}) / (\text{Presisi} + \text{Recall})$	Harmonic mean antara presisi dan recall

Keterangan: TP = True Positive, TN = True Negative, FP = False Positive, FN = False Negative. Selain metrik numerik tersebut, evaluasi juga mencakup confusion matrix untuk memberikan visualisasi detail mengenai pola kesalahan klasifikasi antar kelas penyakit.


4. Hasil dan Pembahasan

4.1 Karakteristik Proses Pelatihan Model

Kurva pelatihan pada Gambar 2 dan Gambar 3 menunjukkan proses konvergensi model PapayaLeafCNN selama 80 epoch. Train loss turun secara konsisten dari sekitar 1,35 menjadi sekitar 0,64, sementara validation loss mengikuti tren serupa meskipun terdapat fluktuasi pada epoch-epoch awal. Hal ini menunjukkan model berhasil belajar tanpa mengalami overfitting yang signifikan. Akurasi pelatihan meningkat dari 37% pada epoch pertama hingga mencapai sekitar 83% pada epoch ke-80, sementara akurasi validasi mencapai sekitar 79%, yang mengindikasikan kemampuan generalisasi model yang baik.



Gambar 2. Kurva Loss per Epoch selama Pelatihan Model PapayaLeafCNN



Gambar 3. Kurva Akurasi per Epoch selama Pelatihan Model PapayaLeafCNN

4.2 Hasil Evaluasi Klasifikasi Keseluruhan


Evaluasi akhir model PapayaLeafCNN dilakukan pada 326 citra data uji yang belum pernah dilihat oleh model selama proses pelatihan. Detail performa per kelas penyakit disajikan pada Tabel 4.

Tabel 4. Hasil Evaluasi Performa Model PapayaLeafCNN per Kelas					
Kelas	Presisi (%)	Recall (%)	F1-Score (%)	Akurasi (%)	Support
Anthracnose	95,56	79,63	86,87	79,6	54
Bacterial Spot	66,67	89,86	76,54	89,9	69
Curl	91,30	71,59	80,25	71,6	88
Healthy	94,29	94,29	94,29	94,3	35
Ring Spot	89,29	93,75	91,46	93,8	80
Accuracy			84,66%		326
Macro Avg	87,42	85,82	85,88		326
Weighted Avg	86,62	84,66	84,82		326


Berdasarkan Tabel 4, model PapayaLeafCNN mencapai akurasi keseluruhan sebesar 84,66% pada 326 citra uji, dengan weighted average precision, recall, dan F1-score masing-masing sebesar 86,62%, 84,66%, dan 84,82%. Kelas Bacterial Spot menunjukkan performa terendah dengan F1-score 76,54%, yang disebabkan oleh tingginya recall (89,86%) namun rendahnya precision (66,67%), mengindikasikan model cenderung over-predict kelas ini. Sebaliknya, kelas Healthy mencapai performa tertinggi dengan F1-score 94,29%, menunjukkan bahwa model mampu membedakan kondisi daun sehat dari yang terinfeksi dengan sangat baik.

4.3 Analisis Performa Per Kelas dan Kesalahan Klasifikasi

Analisis lebih lanjut terhadap hasil klasifikasi per kelas menunjukkan pola yang konsisten. Kelas Ring Spot mencapai F1-score tertinggi kedua sebesar 91,46% dengan recall 93,75%, diikuti Healthy (94,29%) dan Anthracnose (86,87%). Kelas Curl memiliki precision tinggi (91,30%) namun recall rendah (71,59%), yang berarti model cukup akurat ketika memprediksi Curl tetapi melewati sejumlah sampel aktual kelas tersebut. Berdasarkan confusion matrix pada Gambar 4, sebagian besar kesalahan prediksi Curl jatuh ke kelas Bacterial Spot (22 dari 88 sampel), yang mengindikasikan adanya kemiripan visual antara kedua penyakit ini. Grafik per kelas pada Gambar 5 menunjukkan Ring Spot dan Healthy sebagai kelas dengan akurasi tertinggi (93,8% dan 94,3%), sementara Curl memiliki akurasi terendah (71,6%). Kesalahan klasifikasi paling signifikan terjadi pada kelas Curl yang sering salah diprediksi sebagai Bacterial Spot, mengindikasikan bahwa kedua kondisi penyakit tersebut memiliki pola visual yang tumpang tindih sehingga memerlukan data latih yang lebih banyak dan strategi augmentasi khusus untuk meningkatkan kemampuan diskriminasi model.



Gambar 4. Confusion Matrix Model PapayaLeafCNN pada Test Set (5 Kelas)



Gambar 5. Grafik Akurasi Per Kelas Model PapayaLeafCNN pada Test Set

4.4 Pembahasan dan Implikasi

Secara keseluruhan, model PapayaLeafCNN berhasil mencapai akurasi 84,66% dengan macro average F1-score 85,88% pada lima kelas kondisi daun pepaya. Performa ini mencerminkan kemampuan generalisasi model yang baik, khususnya pada kelas Healthy, Ring Spot, dan Anthracnose, yang memiliki karakteristik visual relatif khas dan mudah dibedakan. Kombinasi transfer learning dari bobot ImageNet, strategi regulasi (dropout, L2 weight decay, label smoothing), serta augmentasi data sebesar tiga kali lipat terbukti efektif dalam meningkatkan kemampuan generalisasi model meskipun ukuran dataset asli relatif terbatas.

Di sisi lain, tumpang tindih klasifikasi antara kelas Curl dan Bacterial Spot mengindikasikan keterbatasan model dalam membedakan gejala visual yang serupa, seperti pola bercak dan perubahan tekstur daun yang menyerupai satu sama lain pada tahap awal infeksi. Temuan ini mendukung implementasi model sebagai sistem deteksi penyakit pepaya berbasis citra dalam kondisi lapangan nyata, namun juga menegaskan perlunya strategi tambahan, seperti augmentasi yang lebih ditargetkan pada kelas dengan kemiripan visual tinggi, untuk meningkatkan keandalan model sebelum diterapkan secara luas pada skala pertanian komersial.

5. Simpulan dan Saran

5.1 Simpulan

Penelitian ini berhasil mengembangkan model deep learning berbasis arsitektur Convolutional Neural Network (CNN), yang diberi nama PapayaLeafCNN, untuk klasifikasi multi-penyakit tanaman pepaya berdasarkan citra daun yang mencakup lima kategori kondisi

daun (Healthy, Anthracnose, Bacterial Spot, Curl, dan Ring Spot). Model yang diusulkan mencapai akurasi keseluruhan sebesar 84,66% dengan nilai weighted average F1-score sebesar 84,82% pada data pengujian. Integrasi teknik deep learning melalui penerapan transfer learning dan strategi augmentasi data yang ekstensif terbukti efektif dalam meningkatkan kemampuan generalisasi model. Analisis per kelas menunjukkan bahwa model mampu mendiskriminasi kondisi Ring Spot dan kondisi daun sehat (Healthy) dengan akurasi sangat tinggi, meskipun masih terdapat kendala tumpang tindih klasifikasi pada kondisi daun yang memiliki kemiripan visual tinggi, khususnya antara kelas Curl dan Bacterial Spot.

Penelitian ini memberikan beberapa kontribusi penting dalam bidang pertanian cerdas, yaitu: (1) tersedianya sistem klasifikasi multi-penyakit tanaman pepaya berbasis penglihatan komputer pada citra daun yang akurat untuk lima kategori kondisi daun; (2) metodologi yang dapat diadaptasi untuk klasifikasi penyakit tanaman hortikultura lainnya; dan (3) pipeline pelatihan model deep learning yang komprehensif dengan strategi augmentasi data yang efektif.

5.2 Saran

Berdasarkan temuan dan keterbatasan penelitian ini, beberapa saran diajukan untuk penelitian selanjutnya. Secara metodologis, eksplorasi arsitektur deep learning lain seperti EfficientNet atau Vision Transformer dapat dipertimbangkan untuk meningkatkan kemampuan diskriminasi pada kelas dengan kemiripan visual tinggi, khususnya antara Curl dan Bacterial Spot. Strategi augmentasi yang lebih ditargetkan pada kelas-kelas tersebut, serta penambahan jumlah data latih asli, juga disarankan untuk mengurangi tumpang tindih klasifikasi. Secara praktis, penelitian selanjutnya disarankan untuk melibatkan uji coba sistem pada kondisi lapangan yang lebih beragam, mengeksplorasi pendekatan federated learning untuk pelatihan model yang menjaga privasi data petani, serta mengintegrasikan sistem ini ke dalam aplikasi mobile yang dapat digunakan langsung oleh petani di lahan pertanian guna mendukung deteksi dini penyakit secara real-time.

Referensi

- Aboelenin, S., F. A. Elbasheer, M. M. Eltoukhy, W. M. El-Hady, & K. M. Hosny. 2025. A hybrid framework for plant leaf disease detection and classification using convolutional neural networks and vision transformer, *Complex & Intelligent Systems*, vol. 11, Art. 142.
- Ahmed, F., dkk. 2023. Machine Learning-Based Tea Leaf Disease Detection: A Comprehensive Review, *ArXiv / Springer*.
- Ashtagi, R., dkk. 2025. Image preprocessing permits the machine learning model to concentrate on the main features, *Journal of Agronomy*.
- Banarase, S. J. & S. D. Shirbahadurkar. 2024. Enhancing papaya leaf disease detection with CNN and transfer learning fusion for precise disease diagnosis, *Journal of Electrical Systems*, vol. 20, no. 2s, pp. 1015–1024.
- Brahimi, M., dkk. 2023. Deep learning for plant diseases: Classification and symptoms visualization in modern agriculture, *Applied Artificial Intelligence*.
- Chen, C., dkk. 2025. Edge computing and lightweight convolutional neural networks for real-time papaya leaf disease detection, *Artificial Intelligence in Agriculture*, vol. 7, pp. 234-245.

- Gani, R., dkk. 2025. Attention guided convolutional neural network with explainable AI for papaya leaf disease detection in edge and drone agricultural systems, *Scientific Reports*, vol. 15, Art. 41489.
- Hurtado, J., dkk. 2023. Traditional algorithms to eliminate scene changes from recognition results in natural environments, *IEEE Access*.
- Hasan, M. K., dkk. 2023. Overcoming class imbalance in agricultural image classification using advanced data augmentation techniques, *Computers and Electronics in Agriculture*, vol. 210, Art. 108040.
- Isty, M. N., dkk. 2023. A comprehensive review on Plant Leaf Disease detection using Deep learning, *ArXiv*.
- Kamilaris, A. & F. X. Prenafeta-Boldú. 2022. Deep learning in agriculture: A comprehensive review and recent advancements, *Computers and Electronics in Agriculture*.
- Kaur, K., dkk. 2024. Experimental Evaluation of Deep Learning Based Plant Leaf Disease Detection System, *SciTePress*.
- Karthikeyan, S., R. Charan, S. Narayanan, & L. J. Anbarasi. 2025. Enhanced plant disease classification with attention-based convolutional neural network using squeeze and excitation mechanism, *Frontiers in Artificial Intelligence*, vol. 8, Art. 1640549.
- Kim, D. W. & S. Lee. 2025. Integration of IoT and deep learning for automated plant disease monitoring in smart greenhouses, *IEEE Internet of Things Journal*, vol. 13, no. 4, pp. 4501-4512.
- Kiobia, L., dkk. 2023. Pest infestations require broader criteria for detection, identification, and segmentation, *Smart Agricultural Technology*.
- Madhurya & Jubilson. 2025. Performance Evaluation of Hybrid Deep Learning Architectures for Plant Disease and Severity Classification, *EPJ Web of Conferences*.
- Maity, S., dkk. 2023. Automating pest and disease detection using labeled training data, *Expert Systems with Applications*.
- Mir, T. A., dkk. 2024. Hybridized Model for Improved Papaya Leaf Disease Classification: CNN and Random Forest Integration, *IEEE Xplore*.
- Mustofa, S., M. T. Ahad, Y. R. Emon, & A. Sarker. 2024. BDPapayaLeaf: A dataset of papaya leaf for disease detection, classification, and analysis, *Data in Brief*, vol. 57, Art. 110910.
- Nikith, B. V., dkk. 2023. Deep learning methodologies for plant disease diagnosis and severity estimation, *Journal of Crop Science*.
- Parashar, A., dkk. 2024. Thorough review of various yield prediction models, analyzing their advancements, *Artificial Intelligence in Agriculture*.
- Rahman, A., dkk. 2024. Real-time deployment of lightweight CNN models for tropical plant disease diagnosis on mobile devices, *Journal of Smart Agriculture*, vol. 5, no. 2, pp. 112-125.
- Saad, M. & A. Salman. 2025. One-shot learning techniques with field images for large labeled datasets in agriculture, *Computers and Electronics in Agriculture*.
- Shandilya, G., S. Gupta, H. G. Mohamed, S. Bharany, A. U. Rehman, & S. Hussien. 2025. Enhanced maize leaf disease detection and classification using an integrated CNN-ViT model, *Food Science & Nutrition*, vol. 13, Art. e70513.
- Sharma, R., dkk. 2024. Transfer learning approaches for the detection of foliar diseases in papaya and mango crops, *Frontiers in Plant Science*, vol. 15, Art. 134567.
- Shoaib, M., dkk. 2023. Detection of diseases and pest infestation in plants using machine learning models and computer vision techniques, *Frontiers in Plant Science*.
- Sofuoglu, C. I., dkk. 2024. A robust model requiring large, diverse and balanced dataset for plant leaf disease, *International Journal of Remote Sensing*.

- Suryavanshi, S., dkk. 2024. Agricultural AI: Integrating Federated Learning and CNN in Papaya Leaf Disease Detection, IEEE Xplore.
- Vishnoi, V., dkk. 2023. Effectiveness of CNNs in identifying diseases in apple plants based on leaf images, Multimedia Tools and Applications.
- Xiong, Y., dkk. 2024. Computer-vision-based methods combined with traditional image processing techniques and classifiers to detect plant diseases, Journal of Agricultural Informatics.