



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 4 No. 4 (2026) pp: 10849-10854

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Klasifikasi penyakit daun tanaman cabai menggunakan convolutional neural network (CNN)

Charladinna Arvianne Reyvalda¹, Otong Saeful Bachri, Nur Ariesanto Ramdhan³

¹Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhadi Setiabudi Brebes

²Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhadi Setiabudi Brebes

³Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhadi Setiabudi Brebes

¹Charladinnabeatbox@gmail.com, ²otongsaifulbahriumus@gmail.com, ³ariesantoramdhan@gmail.com

Abstrak

Tanaman cabai (*Capsicum annum L.*) merupakan salah satu komoditas hortikultura penting di Indonesia yang memiliki nilai ekonomi tinggi. Namun, produktivitas tanaman cabai sering mengalami penurunan akibat serangan penyakit daun seperti Bacterial Spot, Cercospora Leaf Spot, Curl Virus, Nutrition Deficiency, dan White Spot. Proses identifikasi penyakit secara manual masih memiliki keterbatasan karena bergantung pada pengalaman pakar, membutuhkan waktu yang relatif lama, serta berpotensi menimbulkan kesalahan subjektif. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit daun cabai secara otomatis menggunakan metode Convolutional Neural Network (CNN) berbasis citra digital. Dataset yang digunakan berupa citra daun cabai berformat RGB yang diperoleh dari sumber publik dan terdiri dari enam kelas, yaitu lima kelas penyakit dan satu kelas daun sehat. Tahapan preprocessing meliputi resizing, normalisasi, dan augmentasi data untuk meningkatkan ketahanan model terhadap variasi kondisi lapangan. Arsitektur CNN dirancang menggunakan beberapa lapisan konvolusi dan max pooling yang diikuti oleh fully connected layer dengan fungsi aktivasi softmax. Proses pelatihan model dilakukan menggunakan optimizer Adam dan fungsi loss categorical cross-entropy. Hasil pengujian menunjukkan bahwa model CNN yang dikembangkan mampu mencapai akurasi klasifikasi sebesar 95%, dengan nilai precision, recall, dan F1-score yang tinggi pada sebagian besar kelas. Dengan demikian, model ini berpotensi diterapkan pada aplikasi berbasis mobile sebagai sistem deteksi dini penyakit daun cabai guna meningkatkan efisiensi dan produktivitas pertanian.

Kata kunci: Convolutional Neural Network, Deep Learning, Klasifikasi Citra, Penyakit Daun Cabai, Deteksi Dini.

1. Latar Belakang

Tanaman cabai (*Capsicum annum L.*) memiliki nilai ekonomi tinggi sebagai komoditas hortikultura utama di Indonesia dengan produksi nasional jutaan ton per tahun. Namun, serangan penyakit daun seperti Bacterial Spot, Cercospora Leaf Spot, Curl Virus, Nutrition Deficiency, White Spot, serta kondisi Healthy Leaf dapat menyebabkan kerugian panen hingga 50%. Deteksi dini penting, tetapi metode tradisional subjektif dan bergantung pada pakar terbatas.

Convolutional Neural Network (CNN) telah terbukti efektif untuk klasifikasi citra penyakit tanaman secara otomatis. Penelitian terkini oleh Naik *et al.*[1], Mustafa *et al.*[2], dan Bezabh *et al.*[3] menunjukkan bahwa berbagai arsitektur CNN mampu mencapai tingkat akurasi yang tinggi dalam mendeteksi penyakit daun tanaman, meskipun masih menghadapi tantangan pada data lapangan yang bersifat variatif. Tujuan penelitian mencakup pembangunan dataset lapangan, pengembangan model CNN custom, pencapaian akurasi $\geq 95\%$ pada enam kelas, serta analisis potensi implementasi mobile untuk petani. Kebaruan terletak pada adaptasi model ringan terhadap variasi pencahayaan dan gejala mirip di lapangan.


Beberapa penelitian terbaru juga melaporkan keberhasilan penerapan CNN dan transfer learning untuk klasifikasi penyakit tanaman dengan akurasi tinggi pada berbagai dataset lapangan[4], [5],[6],[7],[8].

2. Metode Penelitian

Penelitian eksperimental dengan tahapan pengumpulan data, preprocessing, augmentasi, desain model, pelatihan, dan evaluasi menggunakan TensorFlow/Keras di Google Colab.

2.1. Pengumpulan Data

Dataset yang digunakan pada penelitian ini diperoleh sepenuhnya dari sumber **Kaggle**. Data yang digunakan berupa citra daun tanaman cabai (*Capsicum annuum L.*) dalam format RGB. Dataset terdiri atas enam kelas kondisi daun, yaitu *Bacterial Spot*, *Cercospora Leaf Spot*, *Curl Virus*, *Nutrition Deficiency*, *White Spot*, dan *Healthy Leaf*. Untuk menghindari ketidakseimbangan data antar kelas, dilakukan proses *data balancing* sehingga jumlah data pada setiap kelas menjadi seimbang sebelum digunakan pada tahap pelatihan dan pengujian model.



Gambar 1. Contoh Citra Daun Cabai dari Dataset

2.2. Preprocessing dan Augmentasi

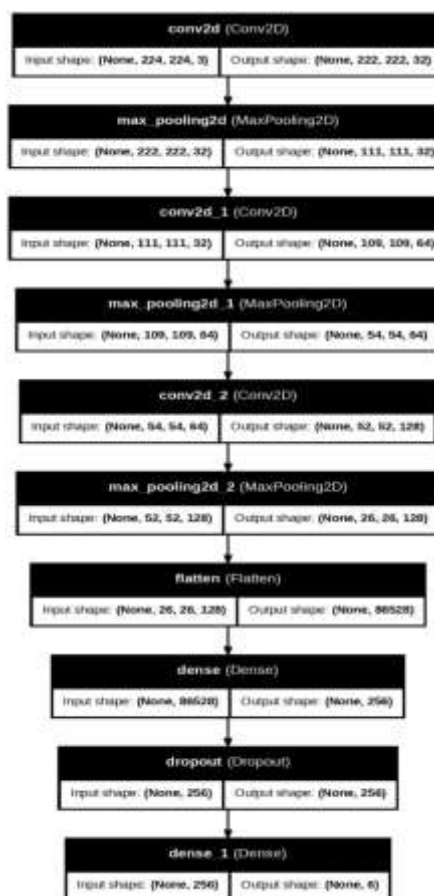
Citra di-resize menjadi 224×224 piksel serta dinormalisasi. Augmentasi data dilakukan secara real-time meliputi rotasi, flip horizontal, zoom, shift, dan penyesuaian brightness untuk mensimulasikan variasi kondisi lapangan sebagaimana diterapkan pada penelitian sebelumnya[9].



Gambar 2. Contoh Citra Daun Cabai Preprocessing dan Augmentasi

2.3. Arsitektur Model

Arsitektur CNN yang digunakan terdiri atas tiga lapisan konvolusi dengan jumlah filter berturut-turut 32, 64, dan 128, yang masing-masing diikuti oleh lapisan max pooling. Selanjutnya, fitur diekstraksi menggunakan flatten layer dan diproses melalui dense layer dengan 256 neuron serta dropout, sebelum menghasilkan output menggunakan fungsi aktivasi softmax, mengacu pada pendekatan CPD-CCNN[10].




Gambar 3. Contoh Citra Daun Cabai Preprocessing dan Augmentasi



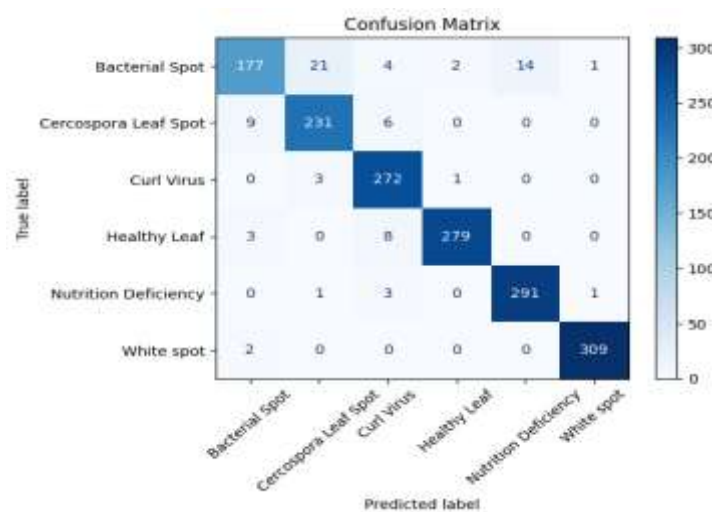
Gambar 4. Grafik Arsitektur Model Training Vs Validation Loss

2.4 Pelatihan dan Evaluasi

Proses pelatihan model dilakukan menggunakan optimizer Adam dengan fungsi loss categorical cross-entropy. Evaluasi performa model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score yang umum digunakan dalam penelitian klasifikasi penyakit tanaman berbasis CNN[11].



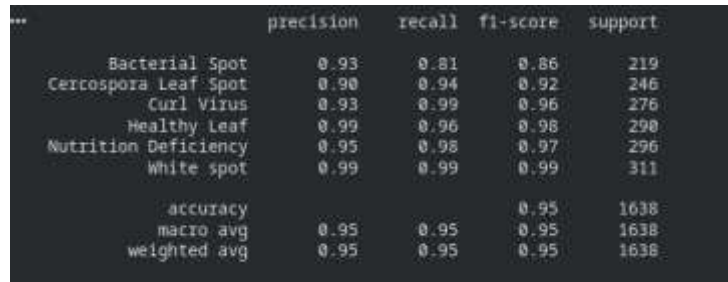
Gambar 5. Model Training Vs Validation Accuracy



Gambar 6. Tabel Prediksi Confusion Matriks

3. Hasil dan Diskusi

Hasil pelatihan model selama 25 epoch menunjukkan proses pembelajaran yang berjalan dengan baik. Nilai *loss* pada data pelatihan mengalami penurunan secara bertahap dan stabil seiring bertambahnya jumlah epoch, yang menandakan bahwa model mampu mempelajari pola fitur citra daun cabai secara efektif. Pada saat yang sama, nilai akurasi menunjukkan tren peningkatan yang konsisten hingga mencapai kondisi konvergen. Hal ini mengindikasikan bahwa proses optimasi berjalan optimal tanpa mengalami fluktuasi yang signifikan. Stabilitas penurunan *loss* dan peningkatan akurasi tersebut menunjukkan bahwa model telah mencapai performa yang cukup baik serta tidak mengalami indikasi *underfitting* selama proses pelatihan.



	precision	recall	f1-score	support
Bacterial Spot	0.93	0.81	0.86	219
Cercospora Leaf Spot	0.90	0.94	0.92	246
Curl Virus	0.93	0.99	0.96	276
Healthy Leaf	0.99	0.96	0.98	290
Nutrition Deficiency	0.95	0.98	0.97	296
White spot	0.99	0.99	0.99	311
accuracy			0.95	1638
macro avg	0.95	0.95	0.95	1638
weighted avg	0.95	0.95	0.95	1638

Gambar 7. Tabel Precision

3.1. Hasil Evaluasi

Akurasi keseluruhan 95% pada data uji.

Tabel 1. Classification Report pada Data Uji

Kelas	Precision	Recall	F1-Score	Support
Bacterial Spot	0.93	0.81	0.86	219
Cercospora Leaf Spot	0.90	0.94	0.92	246
Curl Virus	0.93	0.99	0.96	276
Healthy Leaf	0.99	0.96	0.98	290
Nutrition Deficiency	0.95	0.98	0.97	296
White Spot	0.99	0.99	0.99	311
accuracy			0.95	1638
macro avg	0.95	0.95	0.95	1638
weighted avg	0.95	0.95	0.95	1638

3.2. Pembahasan

Akurasi sebesar 95% yang dicapai oleh model CNN custom menunjukkan performa yang kompetitif untuk dataset yang bersifat variatif dan mencerminkan kondisi lapangan nyata, sejalan dengan penelitian sebelumnya yang menerapkan pendekatan multi-scale feature extraction[12]. Analisis per kelas mengungkapkan bahwa kelas *White Spot* dan *Curl Virus* memiliki performa terbaik, yang disebabkan oleh gejala yang cukup khas dan mudah dikenali oleh model. Sebaliknya, kelas *Bacterial Spot* menunjukkan nilai *recall* yang lebih rendah, yang disebabkan oleh adanya kemiripan visual dengan *Nutrition Deficiency*, sehingga model kadang salah mengklasifikasikan sampel antar kedua kelas tersebut.

Penggunaan teknik augmentasi data terbukti efektif dalam meningkatkan robustitas model terhadap variasi pencahayaan, sudut pengambilan gambar, dan latar belakang daun [13]. Selain itu, model CNN yang ringan secara komputasi sangat potensial untuk diterapkan pada platform mobile sebagai sistem deteksi dini penyakit daun cabai secara real-time. Implementasi ini memiliki potensi besar untuk **mengurangi kerugian panen**,

mendukung strategi **pertanian presisi**, dan membantu petani dalam mengambil keputusan yang lebih cepat dan tepat terkait pemeliharaan tanaman.

4. Kesimpulan

Model CNN custom yang dikembangkan dalam penelitian ini berhasil mengklasifikasikan enam kelas kondisi daun cabai dengan akurasi mencapai 95%. Hasil ini menunjukkan bahwa model mampu mengenali pola fitur pada setiap kelas dengan sangat baik. Salah satu faktor yang mendukung performa tinggi ini adalah penggunaan teknik augmentasi data yang efektif, sehingga model menjadi lebih **robust** terhadap variasi kondisi lapangan, seperti perbedaan pencahayaan, sudut pengambilan gambar, dan latar belakang daun yang berbeda. Meskipun demikian, terdapat kekurangan utama pada model, yaitu kesalahan klasifikasi yang terjadi pada kelas dengan gejala visual yang mirip, misalnya Bacterial Spot dan Nutrition Deficiency. Hal ini menandakan bahwa beberapa fitur halus pada daun masih sulit dibedakan oleh model. Untuk pengembangan selanjutnya, performa model dapat ditingkatkan dengan penerapan attention mechanism atau multi-scale feature extraction [14]. Alternatif lain adalah menggabungkan CNN custom dengan transfer learning menggunakan arsitektur pretrained untuk meningkatkan kemampuan generalisasi model [11]. Strategi-strategi ini berpotensi menghasilkan model yang lebih akurat, lebih stabil, dan siap untuk diterapkan pada aplikasi deteksi dini penyakit daun cabai secara real-time di lapangan.

Referensi

- [1] B. N. Naik, S. K. Meher, and S. K. Sahu, "Detection and classification of chilli leaf disease using a squeeze-and-excitation-based CNN model," *Ecological Informatics*, vol. 69, p. 101663, 2022, doi: 10.1016/j.ecoinf.2022.101663.
- [2] H. Mustafa, A. K. Singh, and R. K. Sharma, "Pepper bell leaf disease detection and classification using optimized convolutional neural network," *Multimedia Tools and Applications*, vol. 82, no. 4, pp. 5671–5690, 2023, doi: 10.1007/s11042-022-13492-4.
- [3] Y. A. Bezabh, T. Alemu, and B. Tilahun, "CPD-CCNN: Classification of pepper disease using a concatenation of convolutional neural network models," *Scientific Reports*, vol. 13, no. 1, pp. 1–14, 2023, doi: 10.1038/s41598-023-42843-2.
- [4] M. Dai, Y. Liu, and J. Zhang, "Pepper leaf disease recognition based on enhanced lightweight convolutional neural networks," *Frontiers in Plant Science*, vol. 14, p. 1230886, 2023, doi: 10.3389/fpls.2023.1230886.
- [5] W. Bao, L. Chen, and X. Huang, "MCCM: Multi-scale feature extraction network for disease classification and recognition of chili leaves," *Frontiers in Plant Science*, vol. 15, p. 1132345, 2024.
- [6] Z. Cai, H. Wang, and Y. Zhou, "IMNM: Integrated multi-network model for identifying pepper leaf diseases," *Frontiers in Plant Science*, vol. 16, p. 1156789, 2025.
- [7] H.-I. Kim, J.-H. Park, and S.-Y. Lee, "Diagnosis of anthracnose of chili pepper using convolutional neural networks," *Plant Pathology Journal*, vol. 41, no. 1, pp. 100–111, 2025.
- [8] J. Too, L. Yujian, S. Njuki, and L. Yingchun, "A comparative study of fine-tuning deep learning models for plant disease identification," *Computers and Electronics in Agriculture*, vol. 161, pp. 272–279, 2019.
- [9] P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Computers and Electronics in Agriculture*, vol. 145, pp. 311–318, 2018.
- [10] R. Sladojevic et al., "Deep neural networks based recognition of plant diseases by leaf image classification," *Computational Intelligence and Neuroscience*, pp. 1–11, 2016.
- [11] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," *Proc. IEEE Conf. Computer Vision and Pattern Recognition*, pp. 1251–1258, 2017.
- [12] C. Szegedy et al., "Going deeper with convolutions," *Proc. IEEE Conf. Computer Vision and Pattern Recognition*, pp. 1–9, 2015.
- [13] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *ICLR*, 2015.
- [14] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Advances in Neural Information Processing Systems*, vol. 25, pp. 1097–1105, 2012.