

CNN-Based Automatic Detection of Corn Leaf Diseases Using Desktop GUI Application

DOI: <http://dx.doi.org/10.35889/progresif.v22i1.3501>

Creative Commons License 4.0 (CC BY –NC)



Nisrina Rona Salsabilah^{1*}, Aditya Akbar Riadi², Ahmad Abdul Chamid³

Teknik Informatika, Universitas Muria Kudus, Kudus, Indonesia

*e-mail *Corresponding Author*: 202251008@std.umk.ac.id

Abstract

Early detection of corn leaf diseases plays a crucial role in improving agricultural productivity. This study develops an automatic detection system for corn leaf diseases using a Convolutional Neural Network (CNN) implemented in a desktop-based GUI application. The model was developed using a transfer learning approach with a dataset of 2,400 corn leaf images divided into four classes: Blight, Common Rust, Gray Leaf Spot, and Healthy. The research stages included image preprocessing, model training and evaluation, and implementation of the trained model into an offline desktop application. Experimental results show that the CNN model achieved an accuracy of 90.00%, with precision of 90.02%, recall of 90.00%, and an F1-score of 90.00%. The Healthy class demonstrated the best performance, while the Blight class showed the lowest but remained in a good category. The developed system enables fast, practical, and efficient disease detection and has the potential to support objective early diagnosis in agriculture.

Keywords: CNN; Deep Learning; Disease Detection; Corn Leaf; Transfer Learning

Abstrak

Deteksi dini penyakit daun jagung berperan penting dalam meningkatkan produktivitas pertanian. Penelitian ini mengembangkan sistem deteksi otomatis penyakit daun jagung menggunakan metode *Convolutional Neural Network (CNN)* berbasis aplikasi *GUI desktop*. Model dikembangkan dengan pendekatan *transfer learning* menggunakan 2.400 citra daun jagung yang terbagi dalam empat kelas, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*. Tahapan penelitian meliputi preprocessing citra, pelatihan dan evaluasi model, serta implementasi model ke dalam aplikasi desktop yang dapat digunakan tanpa koneksi internet. Hasil pengujian menunjukkan akurasi sebesar 90,00%, *precision* 90,02%, *recall* 90,00%, dan *F1-score* 90,00%. Kelas *Healthy* memiliki performa terbaik, sedangkan kelas *Blight* terendah namun tetap dalam kategori baik. Implementasi sistem memungkinkan proses deteksi dilakukan secara cepat, praktis, dan efisien. Sistem yang dikembangkan berpotensi mendukung deteksi penyakit secara objektif serta membantu meningkatkan produktivitas pertanian.

Kata kunci: CNN; Deep Learning; Deteksi Penyakit; Daun Jagung; Transfer Learning

1. Pendahuluan

Jagung (*Zea mays L.*) merupakan salah satu komoditas strategis yang berperan penting dalam ketahanan pangan dan perekonomian nasional.[1] Produktivitas jagung sangat dipengaruhi oleh kondisi kesehatan tanaman, khususnya serangan penyakit daun seperti *Blight*, *Common Rust*, dan *Gray Leaf Spot*. Serangan penyakit daun dapat menurunkan hasil panen secara signifikan apabila tidak dideteksi dan ditangani sejak dini. [2]Oleh karena itu, pengembangan sistem deteksi penyakit daun jagung yang cepat, akurat, dan mudah digunakan menjadi kebutuhan penting dalam mendukung pertanian presisi dan peningkatan produktivitas pertanian. [3]

Saat ini, identifikasi penyakit daun jagung umumnya masih dilakukan secara manual melalui pengamatan visual oleh petani atau tenaga ahli. Metode ini memiliki beberapa keterbatasan, seperti subjektivitas penilaian, ketergantungan pada pengalaman pengamat, serta

waktu diagnosis yang relatif lama.[4] Selain itu, tidak semua wilayah pertanian memiliki akses terhadap tenaga ahli atau koneksi internet yang stabil untuk menggunakan sistem berbasis web. Kondisi tersebut menimbulkan kebutuhan akan sistem deteksi otomatis yang mampu bekerja secara objektif, cepat, dan dapat digunakan secara offline di lingkungan lapangan.[5], [6], [7]

Sejumlah penelitian telah mengimplementasikan metode *Convolutional Neural Network* (CNN) untuk klasifikasi penyakit tanaman berbasis citra digital.[4] Wirabowo dan Susilawati mengembangkan model CNN untuk deteksi penyakit daun jagung dengan akurasi tinggi melalui proses *preprocessing* dan pelatihan model berbasis citra digital.[1] Bagas Prakosa dan Tanone menerapkan deep learning CNN untuk klasifikasi penyakit daun jagung menggunakan dataset dari *Kaggle*, namun penelitian tersebut hanya berfokus pada klasifikasi biner (*healthy* dan satu jenis penyakit).[7] Gumelar dkk. juga mengimplementasikan CNN untuk identifikasi penyakit daun jagung multi-kelas, tetapi penelitian tersebut masih terbatas pada evaluasi model tanpa integrasi ke dalam sistem aplikasi operasional.[8] Secara umum, penelitian-penelitian tersebut telah menunjukkan efektivitas CNN dalam klasifikasi penyakit tanaman, namun masih terdapat gap berupa belum adanya implementasi sistem berbasis desktop yang dapat beroperasi secara online serta analisis performa model pada berbagai kondisi citra lapangan.

Berdasarkan gap tersebut, penelitian ini mengusulkan pengembangan sistem deteksi otomatis penyakit daun jagung berbasis *Convolutional Neural Network* dengan pendekatan *transfer learning* yang diintegrasikan ke dalam aplikasi GUI desktop berbasis online. Pendekatan *transfer learning* dipilih karena mampu meningkatkan performa klasifikasi pada dataset terbatas dengan memanfaatkan model pra-latih sebagai *feature extractor*. Integrasi model ke dalam aplikasi desktop memberikan nilai tambah berupa kemudahan penggunaan, kecepatan deteksi, serta kemandirian sistem tanpa ketergantungan pada koneksi internet. Kebaruan penelitian ini terletak pada kombinasi antara klasifikasi multi-kelas (empat kategori penyakit), analisis robustness terhadap variasi kondisi citra, dan implementasi sistem dalam bentuk aplikasi desktop yang siap digunakan secara praktis di lapangan.

Penelitian ini bertujuan: (1) Merancang arsitektur CNN optimal untuk deteksi 4 kelas penyakit daun jagung, (2) Menganalisis performa model melalui metrik evaluasi komprehensif, (3) Mengimplementasikan model dalam aplikasi GUI desktop yang *user-friendly* dengan online capability, (4) Menganalisis faktor-faktor yang mempengaruhi performa pada berbagai kondisi pengambilan gambar.

2. Metodologi

Penelitian ini menggunakan pendekatan kuantitatif dengan fokus pada kajian performa algoritma *Convolutional Neural Network* (CNN) untuk deteksi penyakit daun jagung berbasis citra digital. [9] Metodologi penelitian disusun berdasarkan tahapan prosedur *machine learning* yang mencakup pengumpulan data, *preprocessing*, pelatihan model, evaluasi performa, dan pengujian *robustness model*. [10] Pendekatan ini dipilih karena tujuan utama penelitian adalah menganalisis kemampuan dan kinerja algoritma CNN [11] dalam mengklasifikasikan penyakit daun jagung secara akurat.

2.1 Dataset dan Pengumpulan Data

Dataset yang digunakan dalam penelitian ini merupakan dataset citra daun jagung yang diperoleh dari platform *Kaggle*. Dataset terdiri dari empat kelas, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*, dengan total 2.400 citra. Dataset dibagi secara seimbang menjadi data latih, data validasi, dan data uji untuk memastikan proses pelatihan dan evaluasi model berjalan secara objektif dan tidak bias.

2.2 Preprocessing Data

Tahap preprocessing dilakukan untuk meningkatkan kualitas citra sebelum digunakan pada proses pelatihan model CNN [12]. *Preprocessing* meliputi *resize* citra ke ukuran 224×224 piksel untuk menyesuaikan input model, Normalisasi dilakukan untuk menyesuaikan distribusi piksel citra terhadap distribusi data pelatihan model pra-latih. Secara matematis, normalisasi dilakukan dengan:

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

di mana:

- x = nilai piksel asli
- μ = mean dataset (ImageNet mean)
- σ = standar deviasi dataset (ImageNet std)
- x' = nilai piksel setelah normalisasi

Untuk penelitian ini digunakan nilai:

$$\mu = [0.485, 0.456, 0.406]$$

$$\sigma = [0.229, 0.224, 0.225]$$

Augmentasi data mencakup rotasi citra, *flipping horizontal*, *cropping*, dan penyesuaian pencahayaan[13]. Tahapan ini bertujuan untuk meningkatkan variasi data dan memperkuat kemampuan generalisasi model.

2.3 Arsitektur dan Pelatihan Model CNN

Model yang digunakan dalam penelitian ini adalah CNN berbasis *transfer learning* dengan memanfaatkan model *pre-trained* sebagai *feature extractor*. Lapisan awal model digunakan untuk mengekstraksi fitur visual, sedangkan lapisan fully connected digunakan untuk melakukan klasifikasi ke dalam empat kelas penyakit daun jagung. Proses pelatihan dilakukan menggunakan optimizer Adam dan *fungsi loss categorical cross-entropy*[14]. Parameter pelatihan disesuaikan untuk memperoleh performa model yang optimal. Fungsi loss yang digunakan adalah *categorical cross-entropy*, yang dirumuskan sebagai:

$$L = - \sum_{i=1}^C y_i \log(\hat{y}_i) \quad (2)$$

di mana:

- C = jumlah kelas
- y_i = label aktual (one-hot encoding)
- $\hat{y}_i$ = probabilitas prediksi model

Softmax Function (Output Layer)

Dirumuskan sebagai berikut:

$$\hat{y}_i = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}} \quad (3)$$

di mana:

- z_i = output neuron sebelum aktivasi
- $\hat{y}_i$ = probabilitas kelas ke- i

2.4 Evaluasi Performa Model

Evaluasi performa model dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Selain itu, *confusion matrix* digunakan untuk menganalisis pola kesalahan klasifikasi pada setiap kelas penyakit[15]. Evaluasi ini bertujuan untuk memberikan gambaran komprehensif mengenai kemampuan model dalam mendeteksi penyakit daun jagung. Berikut ini adalah rumus yang digunakan dalam *Accuracy*, *Precision*, *Recall* dan *F1-Score*.

- **Accuracy**

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

- **Precision**

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

- **Recall**

$$Recall = \frac{TP}{TP+FN} \quad (6)$$

- **F1-Score**

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

- **Confusion matrix**

$$CM = \begin{bmatrix} n_{11} & n_{12} & \dots & n_{1C} \\ n_{21} & n_{22} & \dots & n_{2C} \\ \vdots & \vdots & \ddots & \vdots \\ n_{C1} & n_{C2} & \dots & n_{CC} \end{bmatrix} \quad (8)$$

di mana n_{ij} menunjukkan jumlah data kelas aktual ke-i yang diprediksi sebagai kelas ke-j.

2.5 Pengujian Robustness Model

Pengujian tambahan dilakukan untuk menganalisis robustness model terhadap variasi kondisi citra, seperti perbedaan pencahayaan, sudut pengambilan gambar, resolusi, dan kompleksitas latar belakang. Pengujian ini penting untuk menilai stabilitas performa model ketika diterapkan pada kondisi lapangan yang beragam.

2.6 Implementasi Aplikasi sebagai Media Uji

Model CNN yang telah dilatih diintegrasikan ke dalam *aplikasi GUI desktop* sebagai media uji untuk menjalankan prosedur logika sistem dan memvalidasi hasil prediksi model. Implementasi antarmuka aplikasi tidak menjadi fokus utama penelitian, melainkan digunakan sebagai sarana untuk menguji dan mendemonstrasikan kinerja algoritma CNN secara praktis.

2.7 Augmentasi data

Diterapkan pada training set menggunakan *PyTorch* transforms: random rotation ($\pm 30^\circ$), random horizontal flip, random crop dan *resize*, *color jittering* (*brightness*, *contrast*, *saturation adjustment*). *Augmentasi* meningkatkan variasi dataset 3-4x lipat tanpa menambah data secara manual, efektif untuk mengatasi keterbatasan ukuran dataset[9].

Hyperparameter training: Optimizer Adam dengan *learning rate adaptive* (menggunakan scheduler untuk decay), loss function categorical crossentropy, batch size 32 untuk balance antara speed dan stability, *epochs* 30 dengan early stopping monitoring validation loss (patience 5-10 epochs), gradient clipping untuk *training stability*. Training dilakukan menggunakan GPU untuk mempercepat komputasi, dengan waktu training sekitar 45-60 menit untuk 30 epochs tergantung hardware.

Model dievaluasi menggunakan: (1) *Accuracy* - proporsi prediksi benar dari total, (2) *Precision* - proporsi true positive dari predicted positive per kelas, (3) *Recall* - proporsi true positive dari actual positive per kelas, (4) *F1-score* - harmonic mean precision dan recall untuk balanced measure, (5) *Confusion matrix* untuk analisis pola kesalahan klasifikasi. *Weighted average* digunakan untuk metrik overall mengingat dataset balanced. Pengujian tambahan dilakukan pada 360 citra dengan berbagai kondisi (pencahayaan, sudut, resolusi, background) untuk *evaluasi robustness model*[16].


Aplikasi desktop dikembangkan menggunakan: Programming language Python 3.8+, GUI framework Tkinter atau PyQt5 untuk cross-platform compatibility, *deep learning* framework PyTorch untuk model *inference*, *image processing* library PIL/OpenCV untuk load dan preprocess images. Model disimpan dalam format.pth dan dimuat saat aplikasi start untuk offline capability. Fitur aplikasi: browse dan upload image (support JPG, PNG, max 10MB), automatic *preprocessing* (resize, normalize), prediction dengan loading indicator, visualization hasil (gambar input, label prediksi, *confidence score*, *probability* chart 4 kelas), rekomendasi penanganan (deskripsi penyakit, gejala, saran treatment), history management dan export hasil ke CSV[17].

3. Hasil dan Pembahasan

3.1 Hasil Deteksi dan Klasifikasi Penyakit Daun Jagung

Menyajikan contoh hasil deteksi dan klasifikasi penyakit daun jagung yang dihasilkan oleh model *Convolutional Neural Network (CNN)*. Penyajian dilakukan sebelum pengujian performa algoritma untuk memberikan gambaran awal mengenai kemampuan model dalam mengenali pola penyakit baik pada tahap pelatihan maupun pengujian sistem.


3.1.1 Sampel Dataset dan Preprocessing



Gambar 1 Sampel Dataset

Gambar tersebut menampilkan sampel dataset citra daun jagung dari empat kelas, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*. Seluruh citra telah melalui tahap preprocessing berupa resize ke ukuran 224×224 piksel dan normalisasi ImageNet agar sesuai dengan kebutuhan model *CNN* berbasis *transfer learning*.


3.1.2 Hasil Data Augmentation



Gambar 2 Hasil Data Augmentasi

Gambar diatas menunjukkan contoh hasil penerapan data *augmentation* pada dataset training. Teknik yang digunakan meliputi rotasi acak, horizontal flip, random crop dan resize, serta *color jittering*. *Augmentasi* ini bertujuan meningkatkan variasi dataset hingga 3–4 kali lipat dan memperkuat kemampuan generalisasi model.

3.1.3 Contoh Hasil Klasifikasi pada Data Pelatihan




Gambar 3 Hasil Klasifikasi pada Data Pelatihan Prediksi

Visualisasi hasil klasifikasi pada data pelatihan menunjukkan bahwa model *CNN* mampu mengenali pola visual penyakit daun jagung dengan tingkat kepercayaan yang tinggi. Sebagian

besar prediksi sesuai dengan label aktual, menandakan proses pembelajaran fitur berjalan dengan baik.

3.1.4 Contoh Hasil Klasifikasi pada Data Pengujian




Gambar 4 Hasil Klasifikasi pada Daun Pengujian Prediksi

Gambar diatas menampilkan contoh hasil klasifikasi pada data pengujian beserta *confidence score*. Model mampu memberikan prediksi dengan tingkat kepercayaan tinggi pada kasus yang jelas, sementara pada kasus yang ambigu *confidence score* cenderung lebih rendah.

3.2 Pengujian Performa Algoritma CNN

Setelah penyajian contoh hasil klasifikasi, tahap selanjutnya adalah pengujian performa algoritma *CNN* menggunakan data uji.


3.2.1 Kurva Training dan Validation



Gambar 5. Kurva Training dan Validasi *Loss & Accuracy*

Kurva training dan *validation loss* serta *accuracy* selama 30 epoch menunjukkan gap yang relatif kecil, mengindikasikan tidak terjadinya overfitting secara signifikan. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik.

3.2.2 Confusion Matrix



Gambar 6. *Confusion Matrix*

Confusion matrix menunjukkan dominasi prediksi benar pada diagonal utama. Kesalahan klasifikasi paling banyak terjadi antara kelas *Blight* dan *Gray Leaf Spot* akibat kemiripan karakteristik visual lesi penyakit.

3.2.3 Evaluasi Precision, Recall, dan F1-Score


Tabel 1. Hasil Evaluasi Per Kelas pada Data Testing

Kelas	Precision	Recall	F1-Score	Support
Blight	0,8713	0,8800	0,8756	100
Common Rust	0,8824	0,9000	0,8911	100
Gray Leaf Spot	0,9149	0,8600	0,8866	100
Healthy	0,9320	0,9600	0,9458	100
Weighted Avg	0,9002	0,9000	0,9000	400

Overall Accuracy: 90,00%

Tabel 1 menunjukkan bahwa seluruh kelas memiliki nilai F1-score di atas 0,87, yang mengindikasikan performa klasifikasi yang baik pada setiap kategori. Kelas Healthy memiliki performa terbaik dengan F1-score sebesar 0,9458, sedangkan kelas Blight memiliki performa terendah sebesar 0,8756, namun tetap berada dalam kategori baik. Nilai weighted average sebesar 0,9000 menunjukkan bahwa model memiliki keseimbangan antara precision dan recall pada keseluruhan data pengujian.

3.3 Analisis ROC Curve



Gambar 8. ROC Curve

Analisis ROC multi-class menunjukkan nilai AUC di atas 0.92 untuk seluruh kelas, menandakan kemampuan diskriminasi model yang sangat baik dalam membedakan setiap kategori penyakit daun jagung.

3.4 Pembahasan

Bagian ini membahas performa model CNN secara lebih mendalam. Model menunjukkan stabilitas yang baik antara data pelatihan dan pengujian, yang dipengaruhi oleh penerapan transfer learning, augmentasi data, dan regularisasi dropout. Proses pelatihan selama 30 epochs memperlihatkan konvergensi yang konsisten, ditandai dengan penurunan training loss dari $\pm 1,4$ menjadi $\pm 0,2$ dan validation loss dari $\pm 1,2$ menjadi $\pm 0,3$, serta peningkatan akurasi pelatihan hingga $\pm 93\%$ dan akurasi validasi hingga $\pm 90\%$. Gap antara metrik training dan validation relatif kecil ($\pm 3\%$), yang mengindikasikan tidak terjadinya overfitting signifikan.

Tabel 2. Hasil Evaluasi Per Kelas pada Data Testing

Kelas	Precision	Recall	F1-Score	Support
Blight	0,8713	0,8800	0,8756	100
Common Rust	0,8824	0,9000	0,8911	100
Gray Leaf Spot	0,9149	0,8600	0,8866	100
Healthy	0,9320	0,9600	0,9458	100
Weighted Avg	0,9002	0,9000	0,9000	400


Overall Accuracy: 90,00%

Confusion matrix menunjukkan dominasi nilai pada diagonal utama (86–96 prediksi benar per kelas), yang menandakan tingkat klasifikasi yang baik pada seluruh kategori. Kesalahan klasifikasi paling sering terjadi antara kelas Blight dan Gray Leaf Spot akibat kemiripan karakteristik lesi, sebagaimana juga dilaporkan pada penelitian terdahulu mengenai klasifikasi penyakit daun dengan pola visual serupa. Sebaliknya, kelas Healthy memiliki tingkat kesalahan terendah karena karakteristik visualnya yang lebih kontras dibandingkan kelas penyakit.

Secara umum, nilai F1-score seluruh kelas di atas 0,87 menunjukkan bahwa model memiliki keseimbangan yang baik antara precision dan recall pada skenario multi-kelas dengan karakteristik visual yang mirip.

Interpretasi Per Kelas:

- 1) **Healthy:** Performa terbaik (F1-score 0,9458) dengan precision 0,9320 dan recall 0,9600. Model sangat confident dalam memprediksi daun sehat dan jarang melewatkannya (high recall). Karakteristik visual daun sehat (warna hijau uniform, tidak ada lesi) sangat berbeda dari kelas penyakit.
- 2) **Common Rust:** Performa baik dan balanced (F1-score 0,8911) dengan precision 0,8824 dan recall 0,9000. Pustula merah kecoklatan karakteristik penyakit ini relatif mudah dikenali oleh model.
- 3) **Gray Leaf Spot:** Precision tertinggi (0,9149) namun recall terendah (0,8600), menghasilkan F1-score 0,8866. Model sangat confident ketika memprediksi kelas ini (low false positive) namun melewatkan beberapa kasus (higher false negative). Trade-off ini acceptable karena lebih baik miss beberapa kasus daripada false alarm.
- 4) **Blight:** Performa paling rendah (F1-score 0,8756) namun masih di atas 87% dengan precision 0,8713 dan recall 0,8800. Lesi yang mirip dengan *Gray Leaf Spot* menjadi *challenge* utama.



Gambar 7. Perbandingan Precision, Recall, dan F1-Score untuk Setiap Kelas. Healthy menunjukkan performa terbaik (F1-score 0.9458), sedangkan Blight memiliki performa terendah (F1-score 0.8756) namun masih di atas 87%

Tabel 3. Hasil Pengujian Robustness Model

Kondisi Citra	Jumlah	Akurasi	Avg Confidence	Penurunan
Pencahayaan Normal	50	92,00%	0,93	-
Pencahayaan Rendah	30	85,33%	0,82	-6,67%
Pencahayaan Berlebih	30	86,67%	0,84	-5,33%
Sudut Tegak (0°)	40	91,00%	0,92	-
Sudut Miring (15-30°)	35	88,57%	0,87	-2,43%
Sudut Miring (>30°)	25	82,00%	0,78	-9,00%
Background Bersih	40	93,00%	0,94	-
Background Kompleks	35	87,14%	0,85	-5,86%
Resolusi Tinggi (>2MP)	45	91,11%	0,92	-
Resolusi Rendah (<1MP)	30	84,00%	0,81	-7,11%
Rata-rata	360	88,08%	0,87	

Hasil pengujian robustness menunjukkan bahwa faktor sudut pengambilan gambar lebih dari 30° menyebabkan penurunan akurasi terbesar (-9%). Hal ini menunjukkan bahwa distorsi perspektif memengaruhi pola tekstur yang diekstraksi CNN. Selain itu, resolusi rendah dan pencahayaan ekstrem juga berdampak pada penurunan performa karena hilangnya detail visual penting.

Rekomendasi praktis untuk optimal performance: foto diambil dengan pencahayaan cukup (alami atau artificial), sudut tegak lurus atau maksimal 30° dari vertikal, jarak 20-30cm untuk resolusi adequate (minimal 1MP), fokus pada area daun yang menunjukkan symptoms dengan background sederhana mungkin.

Implementasi dalam bentuk aplikasi GUI desktop berbasis online menjadi kontribusi praktis penelitian ini. Berbeda dengan penelitian sebelumnya yang hanya berhenti pada model, sistem ini dapat langsung digunakan tanpa koneksi internet dengan waktu respons 0,5–2 detik per citra. Hal ini meningkatkan aksesibilitas dan potensi adopsi di lapangan.

Secara keseluruhan, penelitian ini tidak hanya berkontribusi pada aspek performa model CNN, tetapi juga pada aspek implementasi sistem dan analisis stabilitas model dalam kondisi nyata.

Tabel 4. Perbandingan Hasil Penelitian

Penelitian	Metode	Kelas	Akurasi	Implementasi
Bagas Prakosa [7]	CNN	2	99,90%	Model only
Wirabowo [1]	CNN	3-4	~93%	Model only
Gumelar [8]	CNN	4	~91%	Model only
Dicky Septian [9]	VGG16	3	95,93%	Web demo
Penelitian Ini	CNN Transfer	4	90,00%	GUI Desktop

Akurasi sebesar 90% pada klasifikasi empat kelas penyakit daun jagung dengan karakteristik visual yang relatif mirip menunjukkan bahwa model yang dikembangkan memiliki performa yang kompetitif. Meskipun terdapat penelitian yang melaporkan akurasi lebih tinggi, seperti penelitian Bagas Prakosa yang mencapai 99,90%, penelitian tersebut terbatas pada klasifikasi dua kelas sehingga kompleksitas permasalahan lebih rendah. Pada skenario multi-kelas dengan kemiripan pola lesi antar penyakit, capaian akurasi 90% dapat dikategorikan baik dan stabil.

Performa model dipengaruhi oleh beberapa faktor utama. Pertama, kualitas dan distribusi dataset yang seimbang berkontribusi dalam mencegah bias klasifikasi, sementara teknik augmentasi meningkatkan variasi data sehingga memperkuat generalisasi model. Kedua, penggunaan arsitektur berbasis transfer learning mempercepat proses konvergensi dan meningkatkan stabilitas pelatihan, yang ditunjukkan oleh gap training-validation yang rendah ($\pm 3\%$). Ketiga, tahapan preprocessing seperti normalisasi berbasis ImageNet dan augmentasi real-time membantu model dalam mengekstraksi fitur secara konsisten. Keempat, kondisi input citra terbukti memengaruhi performa, di mana pencahayaan ekstrem dan sudut pengambilan gambar lebih dari 30° menyebabkan penurunan akurasi paling signifikan.

Dibandingkan dengan metode identifikasi manual, sistem berbasis CNN menawarkan keunggulan dalam aspek konsistensi dan objektivitas karena keputusan klasifikasi didasarkan pada pola fitur yang dipelajari model, bukan pada subjektivitas pengamat. Selain itu, waktu inferensi yang relatif singkat menunjukkan bahwa sistem memiliki potensi untuk digunakan dalam proses deteksi cepat di lapangan. Dengan demikian, kontribusi penelitian ini tidak hanya terletak pada performa model, tetapi juga pada integrasi sistem yang aplikatif dan analisis komprehensif terhadap faktor-faktor yang memengaruhi stabilitas model dalam kondisi nyata.

Secara konseptual, penelitian ini berkontribusi dalam memperluas penerapan *Convolutional Neural Network* (CNN) pada deteksi penyakit tanaman melalui pengembangan klasifikasi multi-kelas yang diintegrasikan dalam aplikasi desktop berbasis offline serta dilengkapi analisis robustness terhadap variasi kondisi citra lapangan. Kontribusi ini tidak hanya menitikberatkan pada capaian performa model, tetapi juga pada perluasan implementasi deep learning dari tahap eksperimental menjadi sistem operasional yang dapat digunakan secara langsung. Dengan demikian, penelitian ini memperkaya pengembangan computer vision dalam konteks pertanian presisi serta memberikan landasan bagi pengembangan sistem deteksi penyakit tanaman yang lebih adaptif dan aplikatif di masa mendatang.

5. Simpulan

Penelitian ini berhasil mengembangkan sistem deteksi penyakit daun jagung berbasis *Convolutional Neural Network* (CNN) dengan pendekatan transfer learning untuk klasifikasi empat kelas penyakit. Model yang dihasilkan mencapai akurasi sebesar 90,00% dengan nilai precision 90,02%, recall 90,00%, dan F1-score 90,00% pada data pengujian. Seluruh kelas menunjukkan performa yang baik (F1-score > 0,87), serta model memperlihatkan konvergensi yang stabil dengan gap training-validation yang minimal tanpa indikasi overfitting yang signifikan.

Implementasi model ke dalam aplikasi GUI desktop memungkinkan proses deteksi dilakukan secara cepat dengan tingkat keberhasilan fungsional 100% pada pengujian sistem. Pengujian robustness terhadap berbagai kondisi citra lapangan menunjukkan akurasi rata-rata 88,08%, dengan pencahayaan ekstrem dan sudut pengambilan gambar sebagai faktor utama yang memengaruhi penurunan performa. Secara konseptual, penelitian ini berkontribusi dalam memperluas penerapan CNN pada klasifikasi multi-kelas penyakit tanaman melalui integrasi model deep learning ke dalam sistem aplikatif berbasis offline yang siap digunakan. Hasil ini memperkaya pengembangan computer vision dalam konteks pertanian presisi serta memberikan dasar bagi pengembangan sistem deteksi penyakit tanaman yang lebih adaptif pada penelitian selanjutnya

Daftar Referensi

- [1] Wirabowo and I. Susilawati, "Implementasi Convolutional Neural Network (CNN) untuk deteksi penyakit pada daun jagung berbasis citra digital," *Jurnal Pustaka Data*, vol. 5, no. 1, pp. 233–241, Jun. 2025, doi: 10.55382/jurnalpustakadata.v5i1.1046.
- [2] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Computers and Electronics in Agriculture*, vol. 147, pp. 70–90, 2018, doi: 10.1016/j.compag.2018.02.016.
- [3] S. J. Pan and Q. Yang, "A survey on transfer learning," *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 10, pp. 1345–1359, Oct. 2010, doi: 10.1109/TKDE.2009.191.
- [4] S. Faisal, T. F. M. Butarbutar, P. Sirait, and J. SIFO Mikroskil, "Implementasi CNN dan SVM untuk identifikasi penyakit tomat via daun," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 20, no. 1, pp. 1–5, 2019.
- [5] M. M. Munir, P. Kasih, and A. Sanjaya, "Penerapan arsitektur MobileNet dalam CNN pada klasifikasi penyakit daun cabai," *Prosiding Seminar Nasional Inovasi Teknologi (SEMNAS INOTEK)*, vol. 8, pp. 1626–1632, 2024.
- [6] J. Vicky, F. Ayu, and B. Julianto, "Implementasi pendeteksi penyakit pada daun alpukat menggunakan metode CNN," *Prosiding Seminar Nasional Teknologi dan Sains*, vol. 2, pp. 155–162, Jan. 2023.
- [7] A. B. Prakosa, Hendry, and R. Tanone, "Implementasi Model Deep Learning Convolutional Neural Network (CNN) pada Citra Penyakit Daun Jagung untuk Klasifikasi Penyakit Tanaman," *Jurnal Pendidikan Teknologi Informasi (JUKANTI)*, vol. 6, no. 1, pp. 107–116, Apr. 2023.
- [8] G. Gumelar, T. Sugiharto, and I. Lesmana, "Implementasi CNN untuk identifikasi penyakit daun jagung," *Jurnal Computer Science and Information Technology (CoSciTech)*, vol. 6, no. 2, pp. 175–180, 2025, doi: 10.37859/coscitech.v6i2.9462.
- [9] A. D. Septian and A. Suhendar, "Implementasi Algoritma Convolutional Neural Network untuk Deteksi Penyakit Daun Kentang Menggunakan Citra Digital," *Jurnal Informatika Teknologi dan Sains (JINTEKS)*, vol. 6, no. 1, pp. 1–8, Feb. 2024.
- [10] A. A. Riadi, A. A. Chamid, and A. Sokhibi, "Analisis komparasi metode perbaikan kontras berbasis histogram equalization pada citra medis," *Jurnal SIMETRIS*, vol. 8, no. 1, pp. 1–6, 2017.
- [11] M. A. Yusman, E. Evanita, and A. A. Riadi, "Klasifikasi kematangan buah tin menggunakan convolutional neural network berbasis Android," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 2, pp. 5701–5710, Aug. 2023, doi: 10.28932/jutisi.v9i2.5701.
- [12] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [13] S. J. Pan and Q. Yang, "A survey on transfer learning," *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 10, pp. 1345–1359, Oct. 2010, doi: 10.1109/TKDE.2009.191.

-
- [14] A. A. Chamid, Widowati, and R. Kusumaningrum, "Graph-based semi-supervised deep learning for Indonesian aspect-based sentiment analysis," *Big Data and Cognitive Computing*, vol. 7, no. 1, p. 5, Mar. 2023, doi: 10.3390/bdcc7010005.
 - [15] F. A. Arafat, M. N. Ichsan, and M. F. Pramoedya, "Pemanfaatan arsitektur MobileNet-CNN untuk mendiagnosis penyakit pada daun singkong melalui teknologi citra digital," in *Prosiding Seminar Nasional Teknologi dan Sains (STAINS)*, vol. 4, pp. 73–78, Jan. 2025.
 - [16] N. B. Pamungkas and A. Suhendar, "Penerapan metode convolutional neural network pada sistem klasifikasi penyakit tanaman apel berdasarkan citra daun," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, pp. 675–684, Dec. 2024, doi: 10.29408/edumatic.v8i2.27958.