

Implementasi CNN Berbasis Deep Learning Untuk Klasifikasi Penyakit Daun Jagung

Valentiena Prastika Putrie^{1*}, Nur Nafi'iyah²

^{1,2}Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Lamongan

*email: mynaff@unisla.ac.id

ABSTRACT

This study aims to develop and evaluate a convolutional neural network (CNN)-based model for classifying corn leaf diseases using a simple yet effective architecture. Four disease classes were considered: healthy, gray leaf spot, leaf blight, and common rust. A dataset comprising 13,136 images was obtained from the open-source PlantVillage Dataset and processed using class balancing techniques to mitigate prediction bias. Each image was resized to 256×256 pixels, normalized, and split into training (80%) and testing (20%) sets. The proposed CNN architecture consists of four convolutional layers with progressively increasing filters (16, 32, 64, 128), followed by max pooling, dropout, and two fully connected layers. The model was trained for 50 epochs using the Adam optimizer with categorical cross-entropy as the loss function. Performance evaluation, based on accuracy, precision, recall, and F1-score, achieved an accuracy of 97.18% with consistently high metrics across all classes. The results were further visualized using a confusion matrix and classification report. Finally, the trained model was deployed in a Flask-based web application, enabling users to upload corn leaf images and receive automated detection results. These findings demonstrate that a simple CNN architecture can achieve high accuracy in classifying corn leaf diseases and holds significant potential for integration into digital plant disease monitoring systems.

Keywords: CNN, corn leaf, deep learning, plant disease detection, image classification.

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi penyakit daun jagung berbasis *Convolutional Neural Network* (CNN) dengan arsitektur yang sederhana namun efektif. Empat kelas penyakit yang diamati meliputi *healthy*, *gray leaf spot*, *leaf blight*, dan *common rust*. *Dataset* yang terdiri dari 13.136 citra diperoleh dari sumber terbuka *PlantVillage Dataset* dan diproses menggunakan teknik penyeimbangan antar kelas untuk meminimalkan bias prediksi. Setiap citra diubah ukurannya menjadi 256×256 piksel, dinormalisasi, dan dibagi menjadi data latih (80%) dan data uji (20%). Arsitektur CNN yang diusulkan terdiri dari empat lapisan konvolusi dengan jumlah filter yang meningkat secara progresif (16, 32, 64, 128), diikuti *max pooling*, *dropout*, dan dua lapisan *fully connected*. Model dilatih selama 50 *epoch* menggunakan *Adam optimizer* dengan fungsi *loss categorical cross-entropy*. Evaluasi kinerja berdasarkan akurasi, presisi, *recall*, dan *F1-score* menunjukkan bahwa model mencapai akurasi sebesar 97,18% dengan metrik evaluasi yang konsisten tinggi pada seluruh kelas. Hasil tersebut juga divisualisasikan menggunakan *confusion matrix* dan *classification report*. Selanjutnya, model yang telah dilatih diimplementasikan dalam aplikasi *web* berbasis *Flask*, yang memungkinkan pengguna mengunggah citra daun jagung dan memperoleh hasil deteksi secara otomatis. Temuan ini

membuktikan bahwa arsitektur CNN sederhana mampu mencapai akurasi tinggi dalam klasifikasi penyakit daun jagung dan memiliki potensi signifikan untuk diintegrasikan ke dalam sistem monitoring penyakit tanaman berbasis digital.

Keywords: CNN, daun jagung, deep learning, deteksi penyakit tanaman, klasifikasi citra.

PENDAHULUAN

Jagung (*Zea mays*) merupakan salah satu komoditas pertanian strategis di Indonesia yang memiliki peran penting dalam ketahanan pangan nasional. Tanaman ini banyak dibudidayakan karena nilai ekonomisnya yang tinggi serta fleksibilitas penggunaannya, baik sebagai bahan makanan, pakan ternak, maupun bahan baku industri [1]. Namun, produktivitas jagung dapat terganggu oleh berbagai faktor, salah satunya adalah serangan penyakit daun yang umum terjadi di berbagai daerah penghasil jagung [2]. Penyakit daun seperti *gray leaf spot*, *leaf blight*, dan *common rust* sering menimbulkan kerusakan signifikan, dengan potensi penurunan hasil panen mencapai 60% jika tidak ditangani secara tepat [3].

Identifikasi penyakit secara manual yang dilakukan petani sering menghadapi kendala berupa kesulitan membedakan gejala antar penyakit, memerlukan keahlian khusus, dan memakan waktu [4]. Kesalahan diagnosis dapat menyebabkan keterlambatan penanganan dan memperburuk kerusakan tanaman. Seiring perkembangan teknologi, pendekatan berbasis *Artificial Intelligence* (AI), khususnya *deep learning*, menawarkan solusi efektif untuk deteksi otomatis penyakit tanaman berbasis citra digital [5]. Salah satu metode deep learning yang populer adalah *Convolutional Neural Network* (CNN), yang mampu mengekstraksi fitur citra secara bertahap mulai dari pola sederhana hingga kompleks, sehingga meminimalkan kebutuhan ekstraksi fitur manual [6].

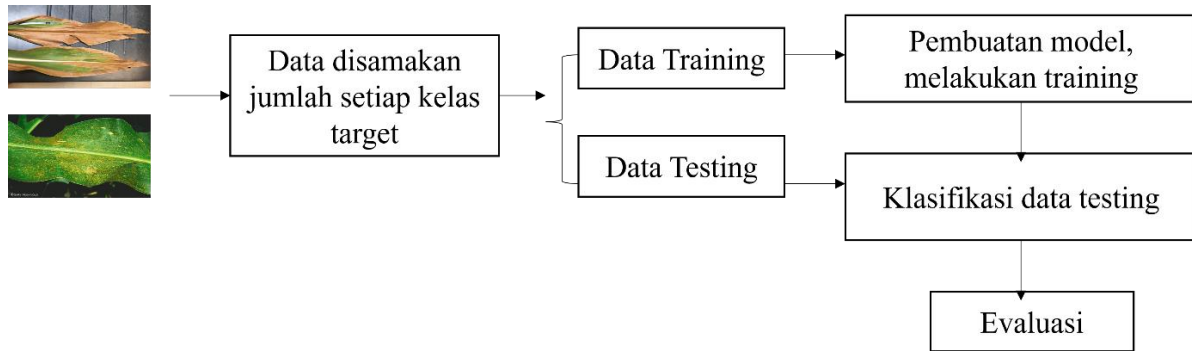
Berbagai penelitian sebelumnya telah memanfaatkan CNN untuk klasifikasi penyakit tanaman, misalnya pada daun gambas [7], paprika [8], serta jagung [9]. Meskipun demikian, sebagian penelitian hanya berfokus pada jumlah kelas terbatas, menggunakan *dataset* kecil, atau tidak mengintegrasikan model ke dalam sistem aplikasi yang siap digunakan di lapangan. Keterbatasan ini menimbulkan kebutuhan akan model yang tidak hanya akurat, tetapi juga ringan dan mudah diimplementasikan.

Penelitian ini mengusulkan model CNN sederhana dengan empat lapisan konvolusi berfilter bertahap (16, 32, 64, 128) untuk mengklasifikasikan empat kondisi daun jagung: sehat (*healthy*), bercak abu-abu (*gray leaf spot*), hawar daun (*leaf blight*), dan karat daun (*common rust*) [10]. Kebaruan penelitian ini terletak pada kombinasi arsitektur CNN sederhana namun efektif dengan integrasi langsung ke aplikasi *web* berbasis *Flask*, sehingga memungkinkan deteksi penyakit secara *real-time* oleh pengguna tanpa memerlukan perangkat keras berkapasitas tinggi.

Dengan demikian, kontribusi utama penelitian ini adalah mengembangkan model CNN sederhana namun andal untuk klasifikasi penyakit daun jagung sekaligus mengintegrasikannya ke dalam aplikasi web praktis. Tujuan penelitian ini adalah menghasilkan sistem deteksi penyakit jagung yang akurat, ringan, dan mudah digunakan sehingga dapat mendukung peningkatan produktivitas pertanian dan mengurangi ketergantungan pada identifikasi manual.

METODE

Pada bagian ini dijelaskan alur tahapan penelitian yang dilakukan. Penelitian ini terdiri dari beberapa tahap utama, yaitu pembagian *dataset*, pembangunan model CNN, pelatihan model, evaluasi, dan penyimpanan model untuk implementasi. Secara garis besar, alur tahapan penelitian ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

Dataset dan Pra-pemrosesan

Dataset awal yang digunakan dalam penelitian ini berjumlah 14.632 citra daun jagung yang diperoleh dari sumber terbuka melalui *platform Kaggle* [11]. *Dataset* ini merupakan kumpulan gambar daun jagung yang telah diberi label berdasarkan kondisi kesehatannya, mencakup empat kategori, yaitu *Corn (Healthy)*, *Corn (Gray Leaf Spot)*, *Corn (Leaf Blight)*, dan *Corn (Common Rust)*. Keempat kategori ini dipilih karena merupakan jenis penyakit daun yang paling umum menyerang tanaman jagung dan memiliki dampak signifikan terhadap produktivitas.

Namun demikian, distribusi awal data tidak seimbang antar kelas. Beberapa kelas memiliki jumlah citra yang jauh lebih banyak dibandingkan kelas lainnya, yang berpotensi menyebabkan model menjadi bias terhadap kelas mayoritas. Untuk mengatasi masalah ini, dilakukan proses *equalization* atau penyeimbangan data, yaitu dengan mengambil jumlah data terkecil dari semua kelas sebagai acuan dan menyamakan jumlah citra untuk masing-masing kategori. Setelah proses penyetaraan ini, setiap kelas terdiri dari 3.284 citra, sehingga total *dataset* akhir yang digunakan untuk penelitian adalah 13.136 citra.

Dataset yang telah diseimbangkan tersebut kemudian dibagi menjadi dua bagian untuk keperluan pelatihan dan pengujian model. Sebanyak 60% (7.880 citra) digunakan sebagai data latih (*training set*), sedangkan 40% sisanya (5.256 citra) digunakan sebagai data uji (*testing set*). Proses pembagian dilakukan secara acak namun tetap mempertahankan proporsi seimbang pada setiap kelas, agar evaluasi model dapat mencerminkan performa secara adil.

Distribusi akhir setelah penyetaraan dan pembagian data dapat dilihat secara lebih rinci pada Tabel 1, yang menampilkan jumlah data untuk masing-masing kelas baik pada data pelatihan maupun pengujian. Pendekatan ini memastikan bahwa model CNN yang dibangun dapat dilatih secara optimal tanpa didominasi oleh satu kelas tertentu, serta mampu melakukan klasifikasi secara adil dan akurat pada semua kategori daun jagung.

Tabel 1. *Balance Dataset*

Kelas	Dataset	Total
-------	---------	-------

	Training (60%)	Testing (40%)	
Common Rust	1970	1314	3284
Gray Leaf Spot	1970	1314	3284
Healthy	1970	1314	3284
Leaf Blight	1970	1314	3284

Tabel 1 menunjukkan bahwa distribusi dataset telah dibuat seragam di setiap kelas dan tahap, sehingga memungkinkan pelatihan model yang adil dan evaluasi performa yang akurat.

Arsitektur dan Pelatihan Model CNN

Model CNN yang digunakan dalam penelitian ini dirancang dengan pendekatan arsitektur bertingkat untuk mengekstraksi fitur visual dari citra daun jagung secara progresif, mulai dari fitur sederhana seperti tepi dan bentuk dasar hingga pola kompleks seperti tekstur dan kerusakan daun [7]. Arsitektur model terdiri dari empat blok konvolusional dengan jumlah filter yang meningkat secara bertahap, yaitu 16, 32, 64, dan 128 filter. Setiap blok terdiri atas beberapa komponen utama, yaitu:

1. *Conv2D layer*: dengan ukuran kernel 3x3, digunakan untuk mendeteksi fitur spasial lokal dari gambar *input*.
2. Fungsi aktivasi ReLU (*Rectified Linear Unit*): digunakan setelah konvolusi untuk menambahkan *non-linearitas* dan mempercepat konvergensi saat pelatihan.
3. *Batch Normalization*: digunakan untuk menstabilkan distribusi *input* antar layer dan mempercepat proses pelatihan.
4. *MaxPooling2D*: dengan ukuran 2x2 digunakan untuk mereduksi dimensi spasial dan mengurangi jumlah parameter sekaligus mencegah *overfitting*.

Setelah keempat blok konvolusional, keluaran fitur dipipihkan melalui lapisan *Flatten*, kemudian diteruskan ke dua lapisan *Dense (fully connected)*. Lapisan *dense* pertama memiliki 128 *neuron* dengan aktivasi *ReLU*, sedangkan lapisan *dense* kedua merupakan lapisan *output* dengan 4 *neuron* yang merepresentasikan masing-masing kelas penyakit daun jagung dan menggunakan fungsi aktivasi *Softmax* untuk menghasilkan probabilitas klasifikasi [9]. Detail struktur dan ukuran *output* dari setiap lapisan ditunjukkan pada Tabel 2.

Tabel 2. Fitur Arsitektur yang digunakan

Layer	Fitur Dan Ukuran Output	Ukuran Kernel	Fungsi Aktivasi
<i>Input</i>	(256, 256, 3)	-	-
<i>Conv2D</i>	(256, 256, 16)	17x17	ReLU
<i>MaxPooling2D</i>	(128, 128, 16)	2x2	-
<i>Conv2D</i>	(128, 128, 32)	3x3	ReLU
<i>MaxPooling2D</i>	(64, 64, 32)	2x2	-
<i>Conv2D</i>	(64, 64, 64)	3x3	ReLU

Tabel 2. Fitur Arsitektur yang digunakan (Lanjutan)

Layer	Fitur Dan Ukuran Output	Ukuran Kernel	Fungsi Aktivasi
<i>MaxPooling2D</i>	(32, 32, 64)	2x2	-
<i>Conv2D</i>	(32, 32, 128)	3x3	ReLU

<i>MaxPooling2D</i>	(16, 16, 128)	2x2	-
<i>Flatten</i>	(32,768)	-	-
<i>Dense</i>	(128)	-	ReLU
<i>Dense</i>	(4)	-	<i>Softmax</i>

Proses Pelatihan Model

Model CNN yang telah dirancang dilatih menggunakan data citra daun jagung sebanyak 7.880 gambar yang terbagi seimbang ke dalam empat kelas, yakni *Common Rust*, *Gray Leaf Spot*, *Leaf Blight*, dan *Healthy*. Setiap kelas terdiri dari 1.970 citra pada set pelatihan, yang sebelumnya telah melalui proses praproses meliputi *resize* ke ukuran 256×256 piksel dan normalisasi nilai piksel.

Pelatihan model dilakukan selama 50 *epoch* dengan ukuran *batch* sebesar 32 [12]. Model menggunakan fungsi *loss Categorical Cross-Entropy*, karena klasifikasi yang dilakukan bersifat *multiclass*. Optimisasi dilakukan menggunakan *Adam optimizer*, yang dikenal efektif dalam mempercepat konvergensi model pada data berukuran besar, dengan *learning rate* awal ditetapkan sebesar 0.001.

Selama proses pelatihan, nilai *accuracy* dan *loss* pada data pelatihan dan validasi direkam setiap *epoch*. Informasi ini kemudian divisualisasikan dalam bentuk grafik untuk memantau stabilitas pelatihan serta mendeteksi adanya gejala *overfitting* atau *underfitting*. Model menunjukkan tren akurasi yang meningkat dan *loss* yang menurun secara konsisten sepanjang proses pelatihan. Model akhir yang telah mencapai performa optimal kemudian disimpan dalam format *.keras* dan dipersiapkan untuk proses integrasi ke dalam aplikasi sistem klasifikasi berbasis *web* [13].

Evaluasi Model

Evaluasi model dilakukan menggunakan 5.256 gambar pengujian yang telah dipisahkan dari data pelatihan. Evaluasi dilakukan berdasarkan empat metrik utama [14], yaitu:

1. Akurasi: mengukur proporsi prediksi yang benar terhadap total data uji.
2. *Precision*: mengukur akurasi prediksi positif untuk setiap kelas.
3. *Recall*: mengukur sejauh mana model berhasil mendeteksi semua data dari masing-masing kelas.
4. *F1-score*: nilai harmonik dari *precision* dan *recall* yang memberikan gambaran menyeluruh terhadap kinerja model.

Selain itu, digunakan *confusion matrix* untuk menunjukkan distribusi prediksi model terhadap label aktual dari masing-masing kelas [15]. Hasil menunjukkan bahwa model mampu mengenali keempat kelas dengan tingkat presisi yang tinggi, terutama pada kelas *Healthy* dan *Common Rust*, yang menunjukkan akurasi mendekati sempurna.

Visualisasi performa pelatihan ditampilkan dalam bentuk grafik akurasi vs *epoch* dan *loss* vs *epoch* yang menunjukkan tren pelatihan berjalan stabil, dengan tidak terdapat gejala *overfitting* signifikan. Hal ini membuktikan bahwa arsitektur sederhana yang digunakan cukup efektif untuk mempelajari pola visual pada citra daun jagung.

Implementasi Sistem

Model Model CNN yang telah dilatih diintegrasikan ke dalam aplikasi *web* berbasis *Flask*, yang memungkinkan pengguna untuk melakukan klasifikasi penyakit daun jagung secara interaktif

[16]. Aplikasi dikembangkan menggunakan bahasa *Python* dan disusun dalam arsitektur sederhana namun fungsional.

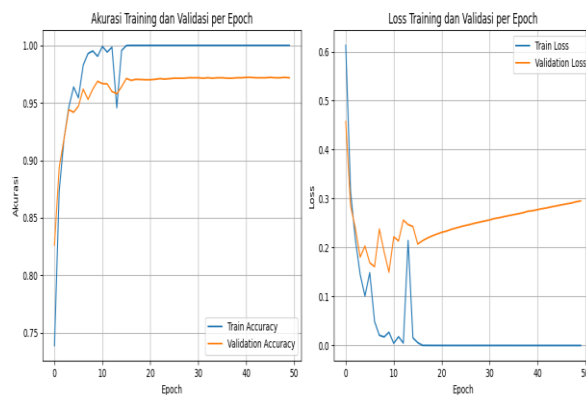
HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pelatihan, evaluasi, dan implementasi model CNN untuk klasifikasi penyakit daun jagung, disertai analisis performa pada setiap tahap.

Hasil Pelatihan Model CNN

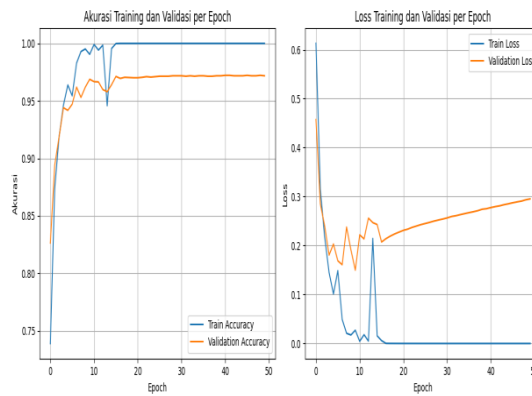
Model CNN dilatih selama 50 *epoch* menggunakan total 7.880 citra daun jagung yang telah dibagi secara seimbang ke dalam empat kelas, yaitu *Healthy*, *Gray Leaf Spot*, *Leaf Blight*, dan *Common Rust*, masing-masing 1.970 citra. Seluruh gambar telah melalui proses *resize* ke 256×256 piksel dengan format RGB dan normalisasi nilai piksel.

Selama proses pelatihan, metrik *accuracy* dan *loss* dicatat pada setiap *epoch* untuk data pelatihan dan validasi. Tujuannya adalah mengevaluasi stabilitas pembelajaran, mendeteksi potensi *overfitting*, dan memastikan model dapat mencapai konvergensi yang baik.



Gambar 2. Grafik Akurasi Pelatihan dan Validasi

Gambar 2 menunjukkan grafik tren kenaikan yang konsisten pada data pelatihan dan validasi. Akurasi pelatihan mencapai 97,18% di akhir pelatihan, sedangkan akurasi validasi tetap stabil tanpa fluktuasi tajam, menandakan model memiliki kemampuan generalisasi yang baik. Pencapaian ini lebih tinggi dari hasil penelitian [9] yang melaporkan akurasi 94,5% pada *dataset* serupa. Jika dibandingkan dengan penelitian [17] yang menggunakan metode CNN untuk mengklasifikasikan empat kelas daun jagung (*Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*) pada *dataset Kaggle* dengan akurasi 84,5%, model CNN pada penelitian ini menunjukkan peningkatan kinerja yang signifikan. Hal ini mengindikasikan bahwa arsitektur yang diusulkan mampu mengekstraksi dan mengklasifikasikan fitur kompleks pada citra lebih efektif dibandingkan penelitian terdahulu dengan pendekatan serupa.



Gambar 3. Grafik Loss Pelatihan dan Validasi

Gambar 3 menunjukkan nilai *loss* pada data pelatihan dan validasi menurun secara konsisten, mengindikasikan bahwa model berhasil belajar dari data secara optimal. Hal ini konsisten dengan temuan pada studi [12], yang menunjukkan bahwa penurunan *loss* yang sejalan dengan peningkatan akurasi merupakan indikator keberhasilan proses pelatihan.

Temuan ini menunjukkan bahwa model CNN sederhana dengan filter bertahap (16–128) mampu mencapai kinerja yang kompetitif bahkan melampaui hasil beberapa penelitian terdahulu. Kebaruan penelitian ini terletak pada penggunaan arsitektur yang ringan namun tetap efektif, disertai teknik penyeimbangan *dataset* untuk mengurangi bias antar kelas, sehingga menghasilkan model yang akurat sekaligus efisien.


Hasil Evaluasi Model

Setelah pelatihan, model dievaluasi menggunakan 5.256 citra uji yang juga terbagi seimbang dalam empat kelas. Hasil evaluasi disajikan dalam Tabel 3 dan Gambar 4.

Tabel 3. *Classification Report*

Kelas	Precision	Recall	F1-Score
Corn__Common__Rust	0.994	1.000	0.997
Corn__Gray__Leaf__Spot	0.961	0.950	0.955
Corn__Healthy	0.985	0.989	0.987
Corn__Leaf__Blight	0.948	0.949	0.948

Nilai *precision* dan *recall* yang tinggi pada Tabel 3 menunjukkan model memiliki kinerja yang seimbang (*balance*). Kelas *Common Rust* mencatat *recall* sempurna (1,000) dan *precision* 0,994, sementara *Gray Leaf Spot* dan *Leaf Blight* memiliki nilai sedikit lebih rendah, kemungkinan karena kemiripan visual bercak daun yang membuat model sulit membedakannya.



Gambar 4. Confusion Matrix

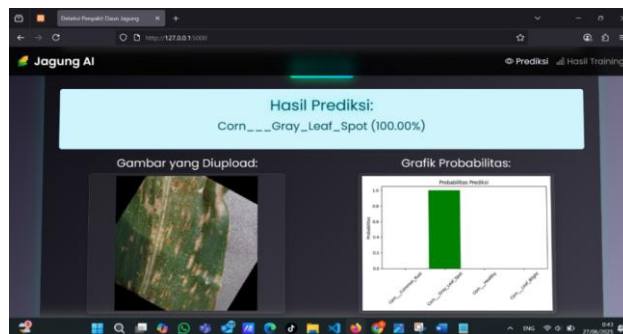
Confusion matrix pada Gambar 4 memperlihatkan kinerja model dalam mengklasifikasikan empat kelas daun jagung: *Corn_Common_Rust*, *Corn_Gray_Leaf_Spot*, *Corn_Healthy*, dan *Corn_Leaf_Blight*. Nilai diagonal utama yang tinggi pada setiap baris menunjukkan mayoritas citra uji berhasil diklasifikasikan sesuai label aslinya.

Seluruh 1.314 citra *Common Rust* teridentifikasi dengan benar. Pada kelas *Healthy*, 1.299 dari 1.314 citra diprediksi tepat, dengan kesalahan minor ke *Gray Leaf Spot* (2 citra) dan *Leaf Blight* (13 citra). Kelas *Gray Leaf Spot* memiliki 1.248 prediksi benar, sementara sisanya salah ke *Common Rust* (4 citra), *Healthy* (6 citra), dan *Leaf Blight* (56 citra), yang kemungkinan disebabkan kemiripan visual gejala bercak dengan *Leaf Blight*. Untuk kelas *Leaf Blight*, 1.247 citra terklasifikasi dengan tepat, sedangkan sisanya salah ke *Common Rust* (4 citra), *Gray Leaf Spot* (49 citra), dan *Healthy* (14 citra). Temuan ini mengindikasikan bahwa sebagian kecil kesalahan terjadi pada kelas yang memiliki karakteristik visual serupa.

Secara umum, distribusi prediksi menunjukkan bahwa model memiliki akurasi tinggi dan kesalahan yang terdistribusi secara merata, tanpa dominasi kesalahan di satu kelas tertentu. Tidak adanya ketimpangan signifikan pada prediksi antarkelas menandakan bahwa model tidak mengalami bias klasifikasi, yaitu kecenderungan lebih “percaya diri” pada satu label dibanding yang lain.

Implementasi Aplikasi Web

Model CNN diintegrasikan ke dalam aplikasi *web* berbasis *Flask* untuk memudahkan pengguna melakukan klasifikasi citra daun jagung secara *real-time*. Aplikasi memiliki antarmuka sederhana dengan fitur unggah gambar, tombol klasifikasi, dan tampilan hasil prediksi beserta persentase keyakinan model.



Gambar 5. Tampilan Aplikasi Klasifikasi Daun Jagung

Antarmuka pada Gambar 5 dirancang agar dapat digunakan oleh petani maupun pengguna tanpa latar belakang teknis. Aplikasi dapat dijalankan secara lokal atau diakses melalui jaringan menggunakan *ngrok*, menjadikannya fleksibel untuk berbagai kondisi penggunaan.

Selain itu, penelitian ini tidak hanya menekankan peningkatan akurasi, tetapi juga menghadirkan kontribusi kebaruan berupa integrasi model CNN sederhana ke dalam aplikasi *web* berbasis *Flask*, yang memungkinkan deteksi penyakit jagung secara *real-time* dan dapat langsung dimanfaatkan oleh petani di lapangan.

KESIMPULAN

Penelitian ini mengembangkan model CNN sederhana dengan konfigurasi filter bertahap (16, 32, 64, 128) untuk klasifikasi empat kondisi daun jagung: *healthy*, *gray leaf spot*, *leaf blight*, dan *common rust*. Model dilatih pada 7.880 citra dan diuji pada 5.256 citra, menghasilkan akurasi 97,18%. Evaluasi menggunakan *precision*, *recall*, *F1-score*, dan *confusion matrix* menunjukkan kinerja tinggi dan seimbang pada seluruh kelas.

Model diintegrasikan ke aplikasi *web* berbasis *Flask*, memungkinkan klasifikasi gambar secara langsung, praktis, dan ramah pengguna. Arsitektur ini terbukti efektif dan efisien, serta memiliki potensi kuat untuk diimplementasikan dalam sistem pertanian digital sebagai solusi deteksi dini penyakit tanaman guna mendukung produktivitas sektor pertanian.

Untuk penelitian selanjutnya, disarankan pengujian pada dataset yang lebih bervariasi dan implementasi model pada perangkat *mobile* atau IoT agar sistem dapat lebih adaptif dan mudah diakses oleh petani secara langsung.

UCAPAN TERIMA KASIH

Penghargaan juga diberikan kepada Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Lamongan, para reviewer, proofreader, serta teknisi yang telah membantu kelancaran penelitian ini. Terima kasih kepada keluarga dan rekan-rekan atas dukungan moril dan motivasi yang diberikan.

DAFTAR PUSTAKA

- [1] Kementerian Pertanian, "Outlook Jagung 2020: Komoditas Pertanian Subsektor Tanaman Pangan," Jakarta, 2020. [Online]. Available: <http://epublikasi.setjen.pertanian.go.id>
- [2] A. Syaiful, B. Suroso, I. Wijaya, M. Iwan, and A. Jalil, "Peran Nutrisi Terhadap Serangan Hama dan Penyakit Tanaman Jagung Pada Berbagai Kondisi Tanah The Role of Nutrition in Pest and Disease Attacks of Corn Plants in Various Soil Conditions," *J. Agrifor*, vol. 22, no. 1, pp. 1–19, 2024, doi: 10.32528/agritrop.v22i1.1875.
- [3] S. Nostra, G. Plena, A. Nurinayah, and F. Putri, "Farm Management of Maize Teknik Pengendalian Penyakit Bercak Daun Gray Leaf Spot (*Cercospora zea- maydis*) pada Tanaman Jagung," Jakarta, 2024. [Online]. Available: <https://edufarmers.org>
- [4] K. Aqla, M. Z. Rakhmatullah, M. Y. Efendi, and Alimin, "Klasifikasi Kualitas Daun Sehat dan Tidak Sehat pada Tanaman Jagung dengan Menggunakan Metode Morfologi Gradien di Python," *J. Sist. Inf. Apl. Teknol. Inf.*, vol. 1, no. 2, pp. 85–94, 2024, doi: 10.53567/josiati.v1i2.15.

- [5] A. Mohammed, Z. Bekeko, and B. Tesso, "Epidemic development and management of common leaf rust (*Puccinia sorghi* Schwein) and turicum leaf blight [*Exserohilum turicum* (Pass .)] of maize (*Zea mays* L .) in eastern Ethiopia," *Agrosystems, Geosci. Environ.*, vol. 6, no. 1, p. e20269, 2023, doi: 10.1002/agg2.20451.
- [6] E. H. Rachmawanto and H. P. Hadi, "Optimasi Ekstraksi Fitur Pada Knn Dalam Klasifikasi Penyakit Daun Jagung," *Din. J. Teknol. dan Inf.*, vol. 22, no. 2, pp. 58–67, 2021, doi: 10.35315/dinamik.v26i2.8673.
- [7] Dwi Fitriana Sari and D. Swanjaya, "Implementasi Convolutional Neural Network Untuk Identifikasi Penyakit Daun Gambas," in *Seminar Nasional Inovasi Teknologi*, Kediri: UN PGRI Kediri, 2020, pp. 137–142.
- [8] S. N. Nugraha, R. Pebrianto, and E. Fitri, "Penerapan Deep Learning Pada Klasifikasi Tanaman Paprika Berdasarkan Citra Daun Menggunakan Metode CNN," *Inf. Syst. Educ. Prof. J. Inf. Syst.*, vol. 8, no. 2, pp. 133–142, 2023, doi: 10.51211/isbi.v8i2.2671.
- [9] A. B. Prakosa, Hendry, and R. Tanone, "Implementasi Model Deep Learning Convolutional Neural Network (CNN) Pada Citra Penyakit Daun Jagung Untuk Klasifikasi Penyakit Tanaman," *J. Pendidik. Teknol. Inf.*, vol. 6, no. 1, pp. 107–116, 2023.
- [10] D. Darmawan, "Implementasi Metode Convolutional Neural Network (CNN) Dalam Mendeteksi Jenis Sampah," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 6, pp. 1331–1338, 2023, doi: 10.25126/jtiik.2023106847.
- [11] N. Hamoin, "Bangladeshi Crops Disease Dataset," -. Accessed: Feb. 14, 2025. [Online]. Available: <https://www.kaggle.com/datasets/nafishamoin/bangladeshi-crops-disease-dataset>
- [12] M. Harahap, Em Manuel Laia, Lilis Suryani Sitanggang, Melda Sinaga, Daniel Franci Sihombing, and Amir Mahmud Husein, "Deteksi Penyakit Covid-19 Pada Citra X-Ray Dengan Pendekatan Convolutional Neural Network (CNN)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 1, pp. 70–77, 2022, doi: 10.29207/resti.v6i1.3373.
- [13] B. T. Chicho and A. B. Sallow, "A Comprehensive Survey of Deep Learning Models Based on Keras Framework," *J. Soft Comput. Data Min.*, vol. 2, no. 2, pp. 49–62, 2021, doi: 10.30880/jscdm.2021.02.02.005.
- [14] D. Bhatt *et al.*, "Cnn variants for computer vision: History, architecture, application, challenges and future scope," *Electron.*, vol. 10, no. 20, pp. 1–34, 2021, doi: 10.3390/electronics10202470.
- [15] J. Hwang, S. Lee, and J. Gil, "Determination of Optimal Batch Size of Deep Learning Models with Time Series Data," *Sustainability*, vol. 16, no. 14, pp. 1–11, 2024, doi: 10.3390/su16145936.
- [16] R. S. Y. Zebua *et al.*, *FENOMENA ARTIFICIAL INTELLIGENCE (AI)*, no. June. Global Eksekutif Teknologi (GET) Press, 2023. [Online]. Available: https://www.researchgate.net/publication/371491224_FENOMENA_ARTIFICIAL_INTELLIGENCE_AI?utm_source=chatgpt.com
- [17] R. F. and N. Nafiyah, "Identifying Types of Corn Leaf Diseases with Deep Learning," *INSYST*, vol. 06, no. 01, pp. 18–23, 2024, doi: 10.52985/insyst.v6i1.347.