

# Deteksi Dini Penyakit Tanaman Jagung Berbasis Transfer Learning dengan Arsitektur DenseNet121

Rima Maulini<sup>1</sup>, Dwirgo Sahlinal<sup>1</sup>, Dian Meilantika<sup>1</sup>, Dani Rofianto<sup>2\*</sup>, Tri Pujiana<sup>3</sup>

<sup>1</sup>Manajemen Informatika, Teknologi Informasi, Politeknik Negeri Lampung, Bandar Lampung, Indonesia

<sup>2</sup>Teknologi Rekayasa Perangkat Lunak, Teknologi Informasi, Politeknik Negeri Lampung, Bandar Lampung, Indonesia

<sup>3</sup>Teknologi Produksi Tanaman Pangan, Budidaya Tanaman Pangan, Politeknik Negeri Lampung, Bandar Lampung, Indonesia

Email: <sup>1</sup>rima\_maulini@polinela.ac.id, <sup>2</sup>dwigosahlinal@polinela.ac.id, <sup>3</sup>dianmeilantika@polinela.ac.id,

<sup>3\*</sup>danirofianto@polinela.ac.id, <sup>4</sup>pujiana.tri@polinela.ac.id

Email Penulis Korespondensi: danirofianto@polinela.ac.id\*

Submitted: 14/11/2025; Accepted: 11/12/2025; Published: 31/12/2025

**Abstrak**—Jagung (*Zea mays L.*) merupakan komoditas pangan strategis di Indonesia yang berperan penting dalam ketahanan pangan, industri pakan ternak, hingga energi terbarukan. Produktivitas jagung kerap menurun akibat penyakit daun seperti *Blight*, *Common Rust*, dan *Gray Leaf Spot*, yang dapat mengurangi hasil panen hingga 30–50% jika tidak dideteksi sejak dini. Metode deteksi konvensional melalui pengamatan visual masih memiliki keterbatasan, antara lain subjektivitas penilaian, kurangnya tenaga ahli, serta keterlambatan dalam pengambilan keputusan. Oleh karena itu, diperlukan pendekatan berbasis kecerdasan buatan yang mampu melakukan deteksi secara cepat, akurat, dan efisien di lapangan. Penelitian ini mengusulkan penggunaan transfer learning dengan arsitektur *DenseNet121* untuk klasifikasi penyakit daun jagung. Dataset yang digunakan terdiri dari 2.818 citra yang terbagi ke dalam empat kelas utama (*Blight*, *Common Rust*, *Gray Leaf Spot*, *Healthy*), diperoleh dari kombinasi dokumentasi lapangan dan dataset terbuka daring. Data kemudian dibagi menggunakan *stratified split* menjadi 68% latih, 17% validasi, dan 15% uji. Hasil pengujian menunjukkan bahwa model mencapai akurasi 93,48% dengan F1-score rata-rata 0,93. Kelas *Healthy* dan *Common Rust* teridentifikasi hampir sempurna, sementara kesalahan klasifikasi masih ditemukan pada *Gray Leaf Spot* yang sering terprediksi sebagai *Blight*. Kurva akurasi dan loss memperlihatkan dinamika pelatihan yang stabil tanpa indikasi *overfitting*, berkat penerapan augmentasi data, dropout, dan *early stopping*. Temuan ini menegaskan bahwa *DenseNet121* berpotensi besar untuk diterapkan dalam sistem deteksi dini penyakit jagung berbasis AI, sekaligus mendukung pengembangan pertanian presisi dan peningkatan produktivitas nasional.

**Kata Kunci:** Transfer learning; DenseNet121; Klasifikasi citra; Penyakit daun jagung; Pertanian presisi

**Abstract**—Corn (*Zea mays L.*) is a strategic food commodity in Indonesia, playing a vital role in food security, livestock feed industries, and even renewable energy. However, its productivity is often threatened by leaf diseases such as *Blight*, *Common Rust*, and *Gray Leaf Spot*, which can reduce yields by up to 30–50% if not detected early. Conventional detection methods through visual observation remain limited due to subjectivity, lack of experts, and delays in decision-making. Therefore, an artificial intelligence based approach is needed to enable fast, accurate, and efficient field detection. This study proposes the use of transfer learning with the *DenseNet121* architecture for classifying corn leaf diseases. The dataset consists of 2,818 images divided into four main classes (*Blight*, *Common Rust*, *Gray Leaf Spot*, *Healthy*), collected from a combination of field documentation and publicly available online sources. The data was split using stratified sampling into 68% training, 17% validation, and 15% testing. Experimental results show that the model achieved an accuracy of 93.48% with an average F1-score of 0.93. The *Healthy* and *Common Rust* classes were identified almost perfectly, while misclassifications were still observed in *Gray Leaf Spot*, which was often predicted as *Blight*. The accuracy and loss curves demonstrate stable training dynamics with no signs of overfitting, thanks to the application of data augmentation, dropout, and early stopping. These findings highlight the strong potential of *DenseNet121* for AI-based early detection of corn diseases, contributing to precision agriculture and enhancing national productivity.

**Keywords:** Transfer learning; DenseNet121; Image classification; Corn leaf disease; Precision agriculture

## 1. PENDAHULUAN

Jagung (*Zea mays L.*) merupakan salah satu tanaman pangan utama di Indonesia setelah padi, yang memiliki peran strategis dalam menjaga ketahanan pangan nasional serta sebagai bahan baku industri pakan ternak, makanan olahan, hingga energi terbarukan [1]. Berdasarkan laporan Badan Pusat Statistik, permintaan jagung terus meningkat seiring pertumbuhan penduduk, kebutuhan pakan unggas, dan perkembangan industri berbasis jagung. Kondisi ini menuntut peningkatan produktivitas jagung, baik dari segi kuantitas maupun kualitas hasil panen. Namun, produktivitas tersebut kerap terganggu oleh serangan penyakit daun seperti *leaf blight*, *gray leaf spot*, dan *common rust*, yang merusak jaringan fotosintetik dan dapat menurunkan hasil panen hingga 30–50% [2]. Situasi ini menegaskan bahwa penyakit daun merupakan ancaman signifikan bagi peningkatan produksi jagung nasional.

Upaya deteksi penyakit jagung selama ini masih mengandalkan pengamatan visual oleh petani atau tenaga ahli. Meskipun umum dilakukan, metode ini bersifat subjektif, sangat bergantung pada pengalaman pengamat, serta sulit diterapkan pada skala lahan yang luas [3]. Selain itu, keterlambatan pengamatan sering menyebabkan penanganan tidak optimal sehingga penyakit terlanjur menyebar. Kondisi ini menunjukkan perlunya sistem deteksi penyakit yang mampu bekerja secara otomatis, cepat, dan konsisten untuk mendukung efisiensi praktik pertanian lapangan. Permasalahan semakin kompleks karena beberapa penyakit memiliki gejala visual yang mirip, sehingga

diagnosis manual berpotensi menimbulkan kesalahan identifikasi. Tidak adanya sistem deteksi otomatis yang mudah digunakan di lapangan juga membuat deteksi dini sulit dilakukan, sehingga penyakit sering terdeteksi pada tahap yang sudah berat. Oleh karena itu, dibutuhkan pendekatan berbasis teknologi yang mampu meningkatkan akurasi identifikasi penyakit sejak tahap awal, memberikan hasil secara real-time, dan tetap mudah digunakan oleh petani.

Seiring berkembangnya teknologi kecerdasan buatan (*Artificial Intelligence*) dan *Computer Vision*, pendekatan berbasis *deep learning* mulai banyak diterapkan dalam deteksi penyakit tanaman [4], [5], [6]. *Convolutional Neural Network* (CNN) terbukti efektif dalam mengekstraksi fitur citra dan mengenali pola visual kompleks pada berbagai kondisi [7], [8], [9]. CNN juga fleksibel dalam menangani variasi tekstur, warna, dan bentuk daun [10], [11]. Namun, pelatihan CNN dari awal membutuhkan dataset besar dan komputasi tinggi, yang menjadi kendala dalam penelitian pertanian yang datanya sering terbatas. *Transfer learning* menjadi solusi ideal untuk mengatasi tantangan tersebut karena memanfaatkan model yang telah dilatih pada dataset besar seperti ImageNet dan menyesuaikannya pada domain tertentu [12]. Pendekatan ini mempercepat pelatihan, meningkatkan akurasi, dan tetap efektif meskipun data terbatas [13], [14]. Oleh karena itu, transfer learning relevan untuk deteksi penyakit tanaman berbasis citra, terutama pada kondisi lapangan yang memiliki keragaman visual tinggi [15].

Berbagai penelitian sebelumnya menunjukkan efektivitas *transfer learning* dalam mendeteksi penyakit tanaman maupun penyakit medis berbasis citra. [16] mengembangkan model CNN berbasis *transfer learning* untuk mendeteksi penyakit daun padi, dengan akurasi mencapai 98% pada citra lapangan. [17] mengusulkan teknik berbasis *deep learning* untuk klasifikasi penyakit pada daun gandum, dengan menggunakan jaringan *generative adversarial* kolaboratif untuk imputasi gambar. Hasil uji menunjukkan metode yang diusulkan mencapai akurasi identifikasi tertinggi 98,44%. Sementara itu, [18] melakukan deteksi objek berbasis YOLOv5 untuk mendeteksi penyakit *Northern Corn Leaf Blight* (NLB) pada tanaman jagung. Hasil eksperimen menunjukkan bahwa model yang diusulkan mencapai akurasi mAP@0.5 sebesar 87,5% pada dataset NLB, yang lebih tinggi 5,4% dibandingkan dengan model asli. Berbagai penelitian sebelumnya menunjukkan efektivitas *transfer learning* dalam mendeteksi penyakit tanaman maupun penyakit medis berbasis citra. [19] mengembangkan model CNN berbasis *transfer learning* untuk deteksi penyakit citrus dengan mekanisme *attention* untuk meningkatkan klasifikasi, menunjukkan hasil yang signifikan dalam akurasi. [20] menggunakan model hibrid CNN-Transformer untuk identifikasi penyakit daun tomat, yang mampu meningkatkan sensitivitas terhadap gejala penyakit yang tidak jelas. [21] menggabungkan *EfficientNetv2* dan Swin Transformer untuk klasifikasi penyakit pada daun tomat dan mencapai hasil yang sangat baik, dengan akurasi lebih dari 98%. [22] menggunakan *Vision Transformers* untuk deteksi penyakit pada daun kapas, dengan akurasi dan efisiensi komputasi yang sangat baik. Penelitian-penelitian ini memperlihatkan bahwa arsitektur hibrid dan pendekatan *attention mechanism* semakin relevan untuk mengatasi masalah klasifikasi penyakit tanaman yang kompleks.

Meskipun berbagai penelitian tersebut memberikan hasil yang menjanjikan, masih terdapat sejumlah celah penting yang belum banyak dieksplorasi secara mendalam. Sebagian besar studi masih berfokus pada komoditas seperti padi, tomat, gandum, kapas, atau citrus, sehingga penelitian khusus mengenai penyakit daun jagung relatif terbatas. Selain itu, walaupun arsitektur seperti *ResNet*, *EfficientNet*, dan *Vision Transformer* telah banyak digunakan dalam bidang ini, pemanfaatan *DenseNet121* secara khusus belum dikaji secara komprehensif, padahal arsitektur ini memiliki keunggulan berupa konektivitas padat yang mampu memaksimalkan aliran informasi antar-lapisan. Lebih jauh, sangat sedikit penelitian yang menilai kemampuan *DenseNet121* dalam membedakan gejala penyakit daun jagung yang memiliki kemiripan visual tinggi pada kondisi lapangan yang bervariasi. Celah-celah tersebut menunjukkan perlunya penelitian lebih lanjut untuk mengevaluasi efektivitas *DenseNet121* sebagai model *transfer learning* yang efisien dan robust dalam deteksi penyakit daun jagung.


Penelitian ini bertujuan untuk mengembangkan model deteksi dini penyakit daun jagung berbasis *transfer learning* menggunakan arsitektur *DenseNet121* yang dikenal efisien dalam mengekstraksi fitur visual meskipun data terbatas. Model ini diarahkan untuk mampu mengidentifikasi jenis penyakit daun jagung secara akurat pada variasi tekstur dan gejala visual yang seringkali saling menyerupai. Selain menguji kinerja *DenseNet121* pada domain penyakit tanaman jagung, penelitian ini juga berupaya membandingkannya dengan pendekatan *deep learning* lain guna memastikan efektivitas arsitektur tersebut dalam konteks pertanian presisi. Harapannya, penelitian ini dapat menghasilkan sistem deteksi penyakit yang cepat, akurat, dan mudah diimplementasikan di lapangan sehingga mendukung petani dalam melakukan deteksi dini dan pengambilan keputusan pengendalian penyakit secara lebih tepat waktu. Lebih jauh, penelitian ini diharapkan memberikan kontribusi ilmiah bagi pengembangan teknologi kecerdasan buatan di sektor pertanian serta menjadi landasan bagi pengembangan aplikasi praktis yang dapat mempermudah monitoring kesehatan tanaman jagung secara berkelanjutan.

## 2. METODOLOGI PENELITIAN

### 2.1. Tahapan Penelitian

Penelitian ini dirancang untuk mengembangkan sistem deteksi dini penyakit daun jagung berbasis *transfer learning* dengan arsitektur *DenseNet121*. Metodologi yang digunakan mencakup tahapan mulai dari pengumpulan dan pembagian dataset, *preprocessing* citra, perancangan model *deep learning*, proses pelatihan, hingga evaluasi


performa model. Setiap tahapan disusun secara sistematis agar dapat menghasilkan model klasifikasi yang akurat, efisien, dan dapat diimplementasikan pada kasus nyata di bidang pertanian presisi. Alur metodologi penelitian ini ditunjukkan pada Gambar 1.



**Gambar 1.** Diagram alur tahapan penelitian

## 2.2. Pengumpulan Dataset

Pada tahap pertama, dataset dikumpulkan dari berbagai sumber citra daun jagung yang sehat dan terinfeksi penyakit. Dataset ini kemudian dibagi menjadi dua bagian: data latih (*training set*) dan data uji (*test set*). Pembagian data ini sangat penting untuk memastikan bahwa model yang dikembangkan dapat dievaluasi secara objektif tanpa terpengaruh oleh data yang digunakan untuk pelatihan. Data yang digunakan dalam penelitian ini berupa citra daun jagung yang terbagi ke dalam empat kelas utama, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*. Sumber data berasal dari kombinasi dokumentasi lapangan dan dataset terbuka daring. Jumlah keseluruhan citra adalah 2.818 gambar dengan distribusi yang relatif seimbang pada setiap kelas, sebagaimana ditunjukkan pada Gambar 2 (a). Selanjutnya, dataset dibagi ke dalam tiga subset menggunakan metode stratified split, yaitu 68% data latih (1.916 citra), 17% data validasi (479 citra), dan 15% data uji (423 citra). Proporsi pembagian ini dipilih untuk memastikan setiap subset memiliki representasi kelas yang setara sekaligus menjaga keseimbangan data. Visualisasi pembagian dataset ditunjukkan pada Gambar 2 (b). Selanjutnya contoh citra daun jagung dari setiap kelas dataset disajikan dalam Gambar 3.



**Gambar 2.** (a) Distribusi Dataset per Kelas, (b) Distribusi Dataset Berdasarkan Subset



**Gambar 3.** Contoh citra daun jagung dari setiap kelas dataset (*Healthy*, *Leaf Blight*, *Gray Leaf Spot*, *Common Rust*)

## 2.3. Praproses Data

Sebelum data digunakan untuk pelatihan model, citra yang telah dikumpulkan melalui proses pengambilan gambar akan diproses melalui beberapa tahap praproses data. Langkah ini meliputi:


- Normalisasi Citra**  
Menyesuaikan skala piksel gambar agar sesuai dengan input model DenseNet121.
- Augmentasi Data**  
Proses ini dilakukan untuk meningkatkan keberagaman data latih dan membantu model untuk lebih robust terhadap variasi data yang mungkin ditemui di dunia nyata, seperti rotasi, flipping, atau perubahan skala pada gambar.
- Pengurangan *Noise* dan Peningkatan Kualitas Gambar**  
Melakukan teknik untuk mengurangi noise dalam gambar yang dapat mengganggu akurasi model.

- d. Setiap citra diubah ukurannya menjadi  $224 \times 224$  piksel sesuai masukan *DenseNet121*. Selanjutnya dilakukan normalisasi nilai piksel ke rentang  $[0,1]$  untuk mempercepat konvergensi. Proses augmentasi (*rotasi, flipping, zooming, shifting*) diterapkan guna memperluas variasi citra dan mengurangi risiko *overfitting*.

## 2.4. Pembuatan Model Transfer Learning

Pada penelitian ini, digunakan arsitektur *DenseNet121* sebagai model dasar *transfer learning*. *DenseNet121* memiliki karakteristik unik berupa *dense connectivity*, yaitu setiap lapisan menerima masukan dari semua lapisan sebelumnya. Desain ini memungkinkan aliran gradien tetap stabil, mengurangi risiko *vanishing gradient*, serta meningkatkan efisiensi penggunaan parameter. Selain itu, struktur konektivitas padat memperkaya representasi fitur karena informasi dari lapisan awal tetap terdistribusi hingga ke lapisan akhir.

Dalam implementasinya, lapisan *fully connected* (FC) asli pada *DenseNet121* diganti dengan lapisan kustom agar sesuai dengan jumlah kelas target. Untuk memperjelas rancangan model yang digunakan, Gambar 4 menampilkan arsitektur *DenseNet121* yang telah dimodifikasi. Pada tahap awal, citra daun jagung berukuran  $224 \times 224$  piksel dimasukkan sebagai input, kemudian diproses melalui *dense blocks* dan *transition layers* yang sebelumnya sudah dilatih menggunakan dataset *ImageNet*. Bagian akhir arsitektur dimodifikasi dengan penambahan *Global Average Pooling* (GAP), lapisan *Dropout* dengan nilai 0.5, serta lapisan *Fully Connected* dengan aktivasi *Softmax* untuk menghasilkan klasifikasi ke dalam empat kelas target (*Blight, Common Rust, Gray Leaf Spot, dan Healthy*).



Gambar 4. Arsitektur *DenseNet121* yang Dimodifikasi untuk Klasifikasi Penyakit Daun Jagung

## 2.5. Pelatihan Model

Setelah model yang sudah diproses diterapkan, tahap berikutnya adalah pelatihan model menggunakan data latih yang telah disiapkan. Selama proses pelatihan, model *DenseNet121* akan diperbarui bobotnya melalui *backpropagation* menggunakan optimasi berbasis *gradient descent*. Dalam hal ini, model belajar untuk mengklasifikasikan gambar daun jagung menjadi dua kelas: sehat atau terinfeksi penyakit. Selama pelatihan, parameter model (seperti *learning rate* dan jumlah *epoch*) diatur dan diuji untuk mendapatkan konfigurasi yang optimal. Proses pelatihan dilakukan menggunakan *optimizer Adam* dengan *learning rate* 0.0001, batch size 32, dan jumlah *epoch* sebanyak 25. Fungsi *loss* yang digunakan adalah *categorical cross-entropy*. Untuk mencegah *overfitting*, digunakan teknik *early stopping* berdasarkan performa validasi.

## 2.6 Evaluasi Model

Setelah proses pelatihan selesai, tahap terakhir adalah pengujian dan evaluasi kinerja model menggunakan data uji yang telah disiapkan sebelumnya. Model yang sudah dilatih diuji untuk memastikan kemampuannya dalam mengklasifikasikan citra daun jagung yang belum pernah dilihat sebelumnya. Beberapa metrik evaluasi yang digunakan antara lain:

- a. Akurasi  
Mengukur seberapa banyak prediksi model yang benar.
- b. Presisi dan *Recall*  
Untuk mengukur kemampuan model dalam mengidentifikasi dengan benar daun jagung yang terinfeksi penyakit.
- c. *F1-Score*  
Menyediakan gambaran keseluruhan dari kinerja model, khususnya dalam menghadapi dataset yang tidak seimbang.
- d. *Confusion Matrix*  
Untuk mengidentifikasi sejauh mana model bisa membedakan antara kelas sehat dan terinfeksi penyakit. Hasil evaluasi ini memberikan gambaran tentang seberapa baik model dapat digunakan dalam konteks dunia nyata, khususnya dalam mendeteksi penyakit daun jagung.

# 3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil pengujian model deteksi penyakit daun jagung menggunakan arsitektur *DenseNet121* berbasis *transfer learning*. Hasil yang ditampilkan mencakup kinerja model selama pelatihan, evaluasi pada data uji, serta analisis visual terhadap prediksi benar maupun salah klasifikasi. Setiap hasil kemudian dibahas secara mendalam untuk menilai keakuratan model, keterbatasan yang masih ditemui, serta implikasi yang dapat ditarik bagi pengembangan sistem deteksi dini penyakit tanaman di lapangan.




### 3.1 Hasil Eksperimen

#### 3.1 Dinamika Pelatihan (*Learning Curves*)

Proses pelatihan model *DenseNet121* menghasilkan kurva akurasi dan loss sebagaimana ditunjukkan pada Gambar 5. Grafik ini memberikan gambaran yang cukup komprehensif mengenai bagaimana model mempelajari pola visual dari dataset sepanjang 25 *epoch*. Dari kurva akurasi, terlihat bahwa nilai akurasi data latih mengalami peningkatan yang stabil sejak awal pelatihan, hingga akhirnya melampaui 95% pada *epoch-epoch* terakhir. Sementara itu, akurasi validasi tampak stabil pada kisaran 90% dan tidak menunjukkan fluktuasi besar. Stabilitas ini mengindikasikan bahwa model mampu mempertahankan performa tanpa terpengaruh secara signifikan oleh noise ataupun variasi data validasi.

Pola akurasi tersebut juga memperlihatkan bahwa strategi augmentation yang diterapkan berperan cukup besar dalam membantu model mengenali variasi bentuk, orientasi, dan pencahayaan pada citra daun. Penggunaan dropout di bagian *fully connected* dan mekanisme *early stopping* juga membantu menjaga kualitas pembelajaran sehingga tidak terjadi *overfitting* yang agresif. Selain itu, pola penurunan loss juga mendukung kesimpulan tersebut. Baik training loss maupun *validation loss* mengalami penurunan yang cukup konsisten hingga mencapai titik stabil. Tidak muncul tanda-tanda kenaikan *validation loss* yang biasanya menunjukkan gejala *overfitting*. Algoritma optimasi Adam dengan *learning rate* 0.0001 terbukti cocok untuk mendukung proses penurunan *loss* ini. Penurunan *loss* yang berjalan selaras dengan peningkatan akurasi menunjukkan bahwa model tidak hanya mampu mengenali pola dengan cepat, tetapi juga mampu mempertahankan informasi penting sepanjang proses pelatihan.


Secara keseluruhan, kurva pelatihan yang stabil baik dari sisi akurasi maupun loss menunjukkan bahwa konfigurasi *hyperparameter* yang digunakan seperti jumlah *epoch*, ukuran *batch*, teknik augmentasi, dan penggunaan bobot *pretrained* telah menghasilkan proses pelatihan yang berjalan efektif dan efisien. Hasil ini cukup meyakinkan untuk membawa model ke tahap evaluasi lanjutan pada data uji.



Gambar 5. Kurva Akurasi dan *Loss* pada Proses *Training*

#### 3.1.2 Evaluasi Kuantitatif pada Data Uji

Setelah model selesai dilatih, tahap selanjutnya adalah evaluasi menggunakan data uji untuk mengetahui sejauh mana kemampuan model dalam mengklasifikasikan citra daun jagung yang tidak pernah dilihat sebelumnya. Evaluasi ini dilakukan menggunakan *confusion matrix* dan *classification report*. *Confusion matrix* yang ditunjukkan pada Gambar 6 menggambarkan bahwa sebagian besar prediksi berada pada diagonal utama, yang menandakan prediksi benar. Kelas *Healthy* dan *Common Rust* menunjukkan akurasi tertinggi dengan prediksi hampir sempurna. Ini menunjukkan bahwa model sangat mudah mengenali daun yang tidak memiliki gejala penyakit maupun gejala penyakit *Common Rust* yang memiliki pola bercak khas berwarna jingga-coklat.



Gambar 6. *Confusion Matrix* Hasil Klasifikasi Penyakit Daun Jagung dengan *DenseNet121*

Di sisi lain, hasil *confusion matrix* juga mengungkapkan adanya kesalahan klasifikasi pada kelas *Gray Leaf Spot* yang beberapa kali teridentifikasi sebagai *Blight*. Kesalahan ini bukan sesuatu yang mengejutkan karena kedua penyakit tersebut memiliki kemiripan visual pada tingkat tertentu. Bercak-bercak berwarna cokelat dengan bentuk agak memanjang dan tepi yang tidak beraturan sering kali menyulitkan baik manusia maupun model dalam mengidentifikasinya secara konsisten. Variasi pencahayaan pada citra lapangan juga menjadi faktor penyulit yang memperbesar kesempatan terjadinya *misclassification*.

*Classification report* pada Gambar 7 memperkuat analisis dari *confusion matrix*. Kelas *Healthy* mempunyai *precision* dan *recall* tinggi dengan *F1-score* sebesar 0.98. Begitu juga kelas *Common Rust* yang mencapai *F1-score* 0.96. Untuk kelas *Blight*, *F1-score* berada pada angka 0.92, yang masih menunjukkan performa baik meskipun terdapat beberapa sampel yang diprediksi sebagai *Gray Leaf Spot*. Kelas *Gray Leaf Spot* sendiri memberikan performa terendah dengan *F1-score* 0.87. Meskipun demikian, nilai ini masih tergolong cukup baik mengingat kemiripan visual antar penyakit yang signifikan.

	precision	recall	f1-score	support
Blight	0.8807	0.9012	0.8908	172
Common_Rust	0.9552	0.9796	0.9673	196
Gray_Leaf_Spot	0.8571	0.7674	0.8098	86
Healthy	1.0000	1.0000	1.0000	175
accuracy			0.9348	629
macro avg	0.9233	0.9120	0.9170	629
weighted avg	0.9339	0.9348	0.9339	629

**Gambar 7.** *Classification Report* Model *DenseNet121* pada Data Uji

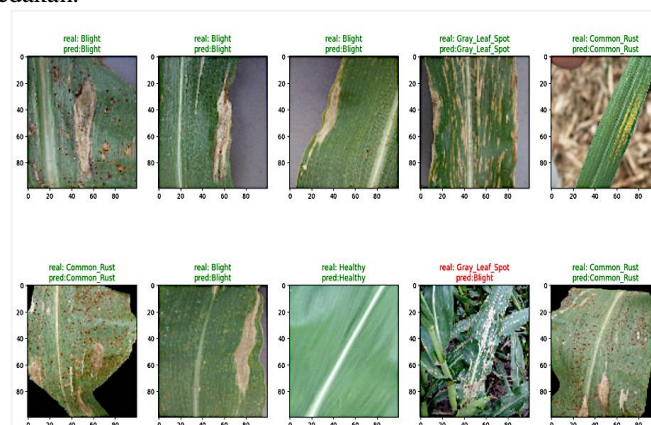
Akurasi keseluruhan model mencapai 93.48% dengan nilai *macro-average* dan *weighted-average* yang seimbang. Angka ini menegaskan bahwa model sudah cukup matang untuk digunakan dalam skenario dunia nyata dan tidak terlalu bias terhadap kelas tertentu. Nilai *F1-score* rata-rata sebesar 0.93 juga menunjukkan bahwa model tidak hanya memprediksi dengan benar tetapi juga memiliki keseimbangan antara kemampuan mendeteksi positif dan negatif.

### 3.1.3. Analisis Visual

Selain evaluasi kuantitatif, analisis visual juga penting untuk memahami bagaimana model *DenseNet121* melakukan prediksi terhadap citra daun jagung. Gambar 8 memperlihatkan beberapa contoh hasil klasifikasi, baik yang benar (*true prediction*) maupun yang salah (*misclassification*).

Pada kasus klasifikasi benar, citra daun sehat maupun yang terinfeksi *Common Rust* dapat dikenali dengan tepat. Hal ini ditunjukkan oleh konsistensi model dalam mengidentifikasi pola tekstur khas, seperti pustula berwarna oranye-cokelat pada *Common Rust* atau permukaan hijau polos pada daun sehat. Prediksi yang benar ini menunjukkan bahwa model mampu mengekstraksi fitur diskriminatif secara efektif melalui konektivitas padat (*dense connectivity*) pada *DenseNet121*. Namun, masih terdapat sejumlah kesalahan klasifikasi, terutama pada kelas *Gray Leaf Spot* yang terkadang diprediksi sebagai *Blight*. Hal ini dapat terjadi karena kemiripan gejala visual berupa bercak berwarna cokelat dengan tepi yang tidak beraturan. Pada citra lapangan, kondisi pencahayaan yang bervariasi, tingkat kerusakan daun yang berbeda, serta tumpang tindih gejala penyakit dapat menyebabkan model sulit membedakan kedua kategori ini.

Analisis kesalahan ini memberikan wawasan penting. Pertama, dataset perlu diperkaya dengan citra *Gray Leaf Spot* yang lebih beragam agar model dapat mempelajari variasi pola lebih baik. Kedua, integrasi teknik *attention mechanism* atau kombinasi dengan arsitektur berbasis *Transformer* berpotensi meningkatkan akurasi pada kelas yang sulit dibedakan.



**Gambar 8.** Hasil Prediksi Model Deteksi Penyakit Daun Jagung

### 3.2. Diskusi

Hasil penelitian ini menunjukkan bahwa penggunaan arsitektur *DenseNet121* berbasis *transfer learning* mampu memberikan performa yang sangat baik dalam mendeteksi penyakit daun jagung dari empat kelas utama, yaitu *Healthy*, *Blight*, *Common Rust*, dan *Gray Leaf Spot*. Akurasi keseluruhan sebesar 93,48% serta *F1-score* rata-rata 0,93 mengindikasikan bahwa model tidak hanya mampu mengenali pola visual secara efektif, tetapi juga konsisten dalam mempertahankan kinerjanya pada data uji. Keberhasilan ini memperkuat temuan bahwa arsitektur *DenseNet*, dengan *dense connectivity* yang menjadi ciri khasnya, dapat menangkap informasi visual yang kompleks secara efisien meskipun dataset tidak terlalu besar. Pola konektivitas yang saling terhubung membantu memastikan bahwa fitur yang diekstraksi pada lapisan awal tetap digunakan hingga lapisan akhir, sehingga representasi fitur yang terbentuk lebih kaya dan lebih lengkap.

Kinerja sangat baik pada kelas *Healthy* dan *Common Rust* menunjukkan bahwa kedua kategori tersebut memiliki ciri visual yang cukup kontras, sehingga lebih mudah dipelajari oleh model. Daun sehat memiliki warna hijau seragam tanpa pola bercak yang mencolok, sedangkan *Common Rust* memiliki pustula berwarna jingga-cokelat yang cukup khas. Konsistensi model dalam memprediksi kedua kelas ini menunjukkan bahwa model mampu memanfaatkan pola tekstur dan warna secara efektif dalam menentukan label citra. Di sisi lain, tantangan utama dalam proses klasifikasi muncul pada kelas *Gray Leaf Spot* dan *Blight*, karena keduanya memiliki kemiripan visual yang cukup tinggi. Lesi pada kedua penyakit ini memiliki bentuk memanjang dan warna kecokelatan yang sering kali sulit dibedakan, terutama pada citra lapangan yang dipengaruhi oleh variasi pencahayaan, *noise*, dan kualitas kamera.

Kesalahan klasifikasi berupa *Gray Leaf Spot* yang diprediksi sebagai *Blight*, dan sebaliknya, merupakan fenomena yang cukup umum dalam klasifikasi penyakit tanaman berbasis citra. Hal ini menunjukkan bahwa meskipun arsitektur *DenseNet121* kuat dalam mengekstraksi fitur, representasi visual antara dua penyakit tersebut tetap saling bertumpang tindih pada *feature space*. Kondisi ini dapat diperburuk oleh adanya bayangan, pencahayaan tidak merata, atau daun yang sudah mengalami tingkat kerusakan tertentu sehingga pola penyakit menjadi tidak terlalu jelas. Variasi ini menunjukkan bahwa performa model sangat sensitif terhadap kualitas data masukan. Oleh karena itu, perbaikan pada sisi dataset seperti penambahan citra *Gray Leaf Spot* dalam kondisi pencahayaan dan tingkat keparahan yang lebih beragam akan memberikan kontribusi signifikan terhadap peningkatan akurasi pada kelas tersebut.

Meskipun tantangan tersebut muncul, kinerja *DenseNet121* tetap dapat dianggap sangat kompetitif jika dibandingkan dengan penelitian-penelitian sebelumnya. Studi berbasis *transfer learning* pada penyakit tanaman umumnya menggunakan arsitektur CNN populer seperti *VGG*, *ResNet*, atau *EfficientNet*. Pada penelitian-penelitian sebelumnya, akurasi yang diperoleh memang lebih tinggi, namun sebagian besar dataset yang digunakan bersifat homogen dan memiliki kualitas pencitraan yang lebih baik. Misalnya, penelitian oleh [20] menggunakan model hibrid CNN-*Transformer* untuk identifikasi penyakit pada daun tomat dan menunjukkan kinerja yang sangat baik, dengan sensitivitas yang tinggi pada kondisi pencahayaan yang tidak seragam. Penelitian ini menggunakan model hibrid yang menggabungkan CNN dan *Transformer* untuk mendapatkan kinerja yang lebih stabil, tetapi untuk dataset yang sangat variatif dan lapangan seperti dalam penelitian ini, *DenseNet121* memberikan keunggulan dari sisi efisiensi parameter dan penggunaan memori. Penelitian lain [21] menggunakan *EfficientNetv2* dan *Swin Transformer* untuk klasifikasi penyakit pada daun tomat juga mencapai hasil yang baik, dengan akurasi tinggi pada dataset yang sangat terkontrol dan homogen. Namun, penelitian ini tidak memperhitungkan variasi kondisi pencahayaan yang terjadi di lapangan, yang merupakan salah satu tantangan terbesar dalam penelitian ini. Di sisi lain, model *DenseNet121* dalam penelitian ini lebih tahan terhadap variasi visual dan gangguan akibat *noise*, yang membuatnya lebih cocok diterapkan dalam kondisi lapangan dengan pencahayaan dan kualitas citra yang bervariasi. Selain itu, penggunaan *Vision Transformers* dalam penelitian [22] untuk deteksi penyakit pada daun kapas menunjukkan hasil yang baik pada dataset yang serupa. Namun, pendekatan berbasis CNN seperti *DenseNet121* lebih unggul dalam mendeteksi pola *fine-grained*, yang sangat dibutuhkan dalam aplikasi pertanian presisi di mana perbedaan kecil dalam gejala penyakit dapat berdampak besar pada hasil akhir klasifikasi.

Secara keseluruhan, model *DenseNet121* tidak hanya memiliki performa yang baik dibandingkan dengan penelitian lain, tetapi juga menunjukkan efisiensi dalam penggunaan parameter dan komputasi. Keunggulan ini menjadikannya model yang lebih ramah terhadap perangkat dengan keterbatasan memori, membuka kemungkinan penerapan pada sistem deteksi berbasis *mobile* atau IoT. Hal ini memberikan solusi praktis yang sangat relevan untuk diterapkan pada perangkat lapangan dengan keterbatasan sumber daya. Selain itu, penelitian ini memperlihatkan bahwa pendekatan *transfer learning* sangat relevan untuk aplikasi pertanian presisi, khususnya dengan memanfaatkan bobot *pretrained* dari *ImageNet*. Pendekatan ini memungkinkan model untuk dilatih lebih cepat dan tetap akurat meskipun jumlah data pelatihan terbatas, memberikan solusi yang sangat berguna bagi sektor pertanian yang sering kali memiliki keterbatasan dalam hal data dan sumber daya komputasi.

Selain aspek-aspek tersebut, penting juga untuk memperhatikan bagaimana model berperilaku pada kondisi-kondisi *ekstrem* yang sering terjadi di lapangan. Misalnya, pada beberapa citra daun yang mengalami kerusakan fisik akibat gesekan angin atau serangan hama, model cenderung mengalami kebingungan karena pola kerusakan tersebut sering menyerupai gejala awal dari penyakit tertentu. Kejadian seperti ini menunjukkan bahwa sistem deteksi berbasis citra harus mempertimbangkan adanya *noise* alami dari lingkungan pertanian, seperti debu,

bercak tanah, atau kerusakan mekanis pada daun yang dapat mengganggu pola visual penyakit sebenarnya. Dalam beberapa kasus, tekstur daun yang tidak rata atau adanya refleksi cahaya yang kuat juga menjadi penyebab kegagalan prediksi, sehingga menegaskan perlunya teknik peningkatan citra atau mekanisme *preprocessing* tambahan pada tahap awal.

Selain itu, variasi kondisi pengambilan gambar seperti perbedaan jarak kamera, sudut pengambilan, hingga stabilitas genggam alat perekam turut memengaruhi performa model. Pada citra yang diambil terlalu dekat, detail bercak penyakit memang terlihat jelas, namun sebagian pola tekstur daun justru hilang sehingga mengubah konteks visual yang seharusnya dipertimbangkan oleh model dalam proses klasifikasi. Sebaliknya, citra yang diambil terlalu jauh dapat menyulitkan model dalam menangkap fitur-fitur kecil seperti pustula pada *Common Rust* atau lesi tipis pada tahap awal *Gray Leaf Spot*. Oleh karena itu, pengembangan standar operasional pengambilan gambar (SOP) dapat menjadi langkah penting untuk memastikan kualitas data yang lebih konsisten dan mendukung performa model secara optimal. Hal ini semakin relevan jika sistem ini akan digunakan oleh petani secara langsung, karena kualitas input yang bervariasi dapat berdampak besar pada keakuratan prediksi di lapangan.

Secara keseluruhan, pembahasan hasil penelitian ini memperlihatkan bahwa *DenseNet121* memiliki kemampuan yang sangat baik untuk mendeteksi penyakit daun jagung, namun masih terdapat ruang untuk pengembangan lebih lanjut. Peningkatan pada sisi kualitas dataset, penggunaan teknik *fine-grained classification*, integrasi *attention mechanism*, serta uji coba pada perangkat lapangan akan memberikan dampak positif terhadap kinerja model secara keseluruhan. Dengan demikian, penelitian ini tidak hanya memberikan kontribusi terhadap pengembangan sistem deteksi penyakit tanaman berbasis citra, tetapi juga membuka peluang besar untuk implementasi nyata dalam mendukung pertanian presisi di Indonesia.

## 4. KESIMPULAN

Penelitian ini membuktikan bahwa penerapan *transfer learning* dengan arsitektur *DenseNet121* mampu mendeteksi penyakit daun jagung secara dini dengan tingkat akurasi 93,48% dan *F1-score* rata-rata 0,93. Hasil ini menunjukkan bahwa *DenseNet121* dapat secara konsisten mengklasifikasikan daun jagung sehat maupun yang terinfeksi *Blight*, *Common Rust*, dan *Gray Leaf Spot*. Kinerja terbaik diperoleh pada kelas *Healthy* dan *Common Rust*, sedangkan kelemahan masih ditemukan pada kelas *Gray Leaf Spot* yang beberapa kali salah diprediksi sebagai *Blight* akibat kemiripan gejala visual. Kurva pelatihan memperlihatkan dinamika yang stabil tanpa indikasi *overfitting* signifikan, menandakan bahwa strategi augmentasi data, *dropout*, dan *early stopping* berhasil menjaga keseimbangan model. Meskipun hasil yang diperoleh sudah memuaskan, penelitian ini masih memiliki ruang untuk pengembangan lebih lanjut. Perluasan dataset dengan jumlah citra lebih besar dan variasi lapangan yang lebih kompleks akan meningkatkan kemampuan generalisasi model, terutama untuk kelas penyakit yang sulit dibedakan. Selain itu, integrasi metode lanjutan seperti *attention mechanism* atau kombinasi CNN–Transformer berpotensi meningkatkan sensitivitas model terhadap detail bercak penyakit. Untuk aplikasi nyata, pengembangan sistem berbasis mobile atau IoT menjadi langkah penting agar hasil penelitian ini dapat langsung dimanfaatkan petani dalam mendeteksi penyakit secara cepat dan praktis.

## REFERENCES

- [1] E. Y. Tarigan, Widiastuty, and A. F. Ahmad Sayu, "Effectiveness of Corn (*Zea mays* ssp L. var. *Saccharata*) Seed Harvesting Speed Using a Mini Combine Harvester in Corn Seed Production," *JURNAL AGRONOMI TANAMAN TROPIS (JUATIKA)*, vol. 7, no. 1, Jan. 2025, doi: 10.36378/juatika.v7i1.3991.
- [2] S. R. B. Siregar and M. S. Sari, "Identification Of Disease And Pathogen Attack Levels On Corn (*Zea mays*) IN BPP Stabat," *Serambi Journal of Agricultural Technology*, vol. 3, no. 2, 2021.
- [3] A. Nampira and A. Mariam, "AI-Assisted Early Detection of Crop Disease Using Hyperspectral Imaging and Deep Learning in Smallholder Farms," *Journal of Multidisciplinary Sustainability Asean*, vol. 2, no. 3, pp. 109–119, 2025, doi: 10.70177/ijmsa.v2i3.2305.
- [4] L. Cunha, "Deep learning with Python (2<sup>a</sup> ed) - François Chollet - Manning, outubro 2021, 504 pp.," *Interações: Sociedade e as novas modernidades*, no. 42, pp. 113–115, Jun. 2022, doi: 10.31211/interacoes.n42.2022.r1.
- [5] J. Heaton, "Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning," *Genet Program Evolvable Mach*, vol. 19, no. 1–2, pp. 305–307, Jun. 2018, doi: 10.1007/s10710-017-9314-z.
- [6] E. Elbasi *et al.*, "Artificial Intelligence Technology in the Agricultural Sector: A Systematic Literature Review," 2023, doi: 10.1109/ACCESS.2022.3232485.
- [7] M. Gao, J. A. Fessler, and H. P. Chan, "Model-based deep CNN-regularized reconstruction for digital breast tomosynthesis with a task-based CNN image assessment approach," *Phys Med Biol*, vol. 68, no. 24, 2023, doi: 10.1088/1361-6560/ad0eb4.
- [8] J. O. N. V. Geronimo, E. D. L. R. Arguelles, and K. J. M. Abriol-Santos, "Automated Classification and Identification System for Freshwater Algae Using Convolutional Neural Networks," *Philipp J Sci*, vol. 152, no. 1, 2023, doi: 10.56899/152.01.25.
- [9] M. G. Lanjewar, P. Morajkar, and P. P., "Modified transfer learning frameworks to identify potato leaf diseases," *Multimed Tools Appl*, vol. 83, no. 17, 2024, doi: 10.1007/s11042-023-17610-0.



- [10] J. Liang, Y. Deng, and D. Zeng, "A Deep Neural Network Combined CNN and GCN for Remote Sensing Scene Classification," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 13, 2020, doi: 10.1109/JSTARS.2020.3011333.
- [11] H. Zhao and Y. Wang, "A Big Data-Driven Financial Auditing Method Using Convolution Neural Network," *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2023.3269438.
- [12] S. Panigrahi, A. Nanda, and T. Swarnkar, "A Survey on Transfer Learning," in *Smart Innovation, Systems and Technologies*, 2021. doi: 10.1007/978-981-15-5971-6\_83.
- [13] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, and C. Liu, "A survey on deep transfer learning," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2018. doi: 10.1007/978-3-030-01424-7\_27.
- [14] W. G. Pamungkas, M. I. P. Wardhana, Z. Sari, and Y. Azhar, "Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease," *Jurnal RESTI*, vol. 7, no. 2, 2023, doi: 10.29207/resti.v7i2.4736.
- [15] S. H. Lee, H. Goëau, P. Bonnet, and A. Joly, "New perspectives on plant disease characterization based on deep learning," *Comput Electron Agric*, vol. 170, 2020, doi: 10.1016/j.compag.2020.105220.
- [16] M. T. Ahad, Y. Li, B. Song, and T. Bhuiyan, "Comparison of CNN-based deep learning architectures for rice diseases classification," *Artificial Intelligence in Agriculture*, vol. 9, 2023, doi: 10.1016/j.aiia.2023.07.001.
- [17] A. Usha Ruby, J. George Chellin Chandran, B. N. Chaithanya, T. J. Swasthika Jain, and R. Patil, "Wheat leaf disease classification using modified ResNet50 convolutional neural network model," *Multimed Tools Appl*, vol. 83, no. 23, 2024, doi: 10.1007/s11042-023-18049-z.
- [18] S. Leng, Y. Musha, Y. Yang, and G. Feng, "CEMLB-YOLO: Efficient Detection Model of Maize Leaf Blight in Complex Field Environments," *Applied Sciences (Switzerland)*, vol. 13, no. 16, 2023, doi: 10.3390/app13169285.
- [19] R. M. Shiny, A. Gladston, and H. Khanna Nehemiah, "A Multi-kernel CNN model with attention mechanism for classification of citrus plants diseases," *Sci Rep*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-08557-3.
- [20] S. Jia, G. Wang, H. Li, Y. Liu, L. Shi, and S. Yang, "ConvTransNet-S: A CNN-Transformer Hybrid Disease Recognition Model for Complex Field Environments," *Plants*, vol. 14, no. 15, Aug. 2025, doi: 10.3390/plants14152252.
- [21] Y. Sun, L. Ning, B. Zhao, and J. Yan, "Tomato Leaf Disease Classification by Combining EfficientNetv2 and a Swin Transformer," *Applied Sciences (Switzerland)*, vol. 14, no. 17, Sep. 2024, doi: 10.3390/app14177472.
- [22] M. Ahmad, "Cotton Leaf Disease Detection Using Vision Transformers: A Deep Learning Approach," *African Journal of Biomedical Research*, pp. 5760–5769, Nov. 2024, doi: 10.53555/ajbr.v27i3s.3421.