

# IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN CITRA DAUN MENGGUNAKAN COVOLUTIONAL NEURAL NETWORK

Dwi Septiyani A\*<sup>1)</sup>, Ema Utami<sup>2)</sup>

1. Magister Informatika, Universitas Amikom Yogyakarta, Indonesia
2. Magister Informatika, Universitas Amikom Yogyakarta, Indonesia

## Article Info

**Kata Kunci :** Convolutional Neural Network (CNN); Penyakit Daun Jagung; Klasifikasi Citra; ResNet-50; Transfer Learning.

**Keywords :** Convolutional Neural Network (CNN); Corn Leaf Disease; Image Classification; ResNet-50; Transfer Learning.

## Article history:

Received 16 Oktober 2025

Revised 23 November 2025

Accepted 27 November 2025

Available online 1 Desember 2025

## DOI :

<https://doi.org/10.29100/jipi.v10i4.9320>

\* Dwi Septiyani A.

Corresponding Author

E-mail address:

[dwiseptiyaniarwin@students.amikom.ac.id](mailto:dwiseptiyaniarwin@students.amikom.ac.id)

## ABSTRAK

Identifikasi penyakit pada daun jagung memiliki peran penting dalam mendukung produktivitas pertanian yang berkelanjutan. Penelitian ini mengusulkan model klasifikasi menggunakan Convolutional Neural Network (CNN) dengan arsitektur ResNet-50 untuk mendeteksi penyakit daun jagung berdasarkan data citra. Dataset yang digunakan terdiri dari empat kategori: Blight, Common Rust, Gray Leaf Spot, dan Healthy, yang diperoleh dari sumber data publik. Pra-pemrosesan data dilakukan melalui perubahan ukuran citra menjadi 224×224 piksel dan peningkatan kontras menggunakan teknik CLAHE. Pengembangan model dilakukan dengan pendekatan transfer learning dan dievaluasi menggunakan metrik akurasi, presisi, recall, F1-score, serta confusion matrix. Hasil eksperimen menunjukkan kinerja klasifikasi yang tinggi dengan akurasi keseluruhan sebesar 94%. Kategori Healthy memperoleh performa terbaik (presisi dan recall = 1.00), sementara kategori Gray Leaf Spot mencatat nilai recall terendah akibat kemiripan visual dengan kategori lain. Penelitian ini membuktikan bahwa model CNN berbasis ResNet-50 sangat efektif untuk klasifikasi otomatis penyakit daun jagung dan berpotensi besar untuk diterapkan dalam sistem pertanian presisi.

## ABSTRACT

*The identification of corn leaf diseases plays a vital role in supporting sustainable agricultural productivity. This study proposes a classification model using a Convolutional Neural Network (CNN) with a ResNet-50 architecture to detect corn leaf diseases from image data. The dataset used consists of four categories: Blight, Common Rust, Gray Leaf Spot, and Healthy, which were collected from publicly available sources. Data preprocessing involved image resizing to 224×224 pixels and contrast enhancement using CLAHE. The model was developed through transfer learning by fine-tuning the ResNet-50 architecture and evaluated using accuracy, precision, recall, F1-score, and confusion matrix. Experimental results show a high classification performance, with an overall accuracy of 94%. The Healthy class achieved the best performance (precision and recall = 1.00), while the Gray Leaf Spot class recorded the lowest recall due to its visual similarity to other classes. This research demonstrates that the ResNet-50-based CNN model is highly effective for automatic classification of corn leaf diseases and has strong potential for practical applications in precision agriculture.*

## I. PENDAHULUAN

Jagung merupakan salah satu tanaman sereal dan bahan pangan yang penting karena mengandung sumber karbohidrat. Ini adalah tanaman pangan terbesar ketiga di dunia setelah beras dan gandum. Di Indonesia, jagung merupakan salah satu tanaman pangan terbesar kedua setelah padi. Tanaman ini memiliki daya hasil yang tinggi dan kegunaan yang luas. Tanaman ini memiliki peran strategis dalam perekonomian nasional dan memiliki fungsi

multiguna, seperti pakan ternak. Dengan kata lain, jagung juga dapat digunakan sebagai bahan baku industri. Dengan kemajuan teknologi, berbagai sektor bisnis merasakan manfaatnya, termasuk industri pertanian [1][2]. Saat ini, penerapan teknologi dalam pertanian sudah menjadi hal yang lazim dan tak terelakkan. Oleh karena itu, pemanfaatan teknologi dalam pertanian diyakini mampu membawa dampak positif bagi para petani. Salah satu contohnya adalah penggunaan teknologi pengolahan citra digital, yang dapat mendeteksi penyakit pada tanaman sehingga membantu dalam upaya pencegahan penyebarannya [3][4]. Jagung merupakan salah satu tanaman pangan utama di dunia, sejajar dengan gandum dan padi. Di Indonesia, jagung menempati posisi strategis sebagai sumber makanan pokok kedua setelah padi serta berperan penting dalam pemenuhan kebutuhan karbohidrat masyarakat. Namun, dalam konteks global, produksi jagung menghadapi tantangan serius yang dapat berdampak langsung pada ketahanan pangan dunia [5][6]. Perubahan iklim, degradasi lahan, serta serangan penyakit tanaman menjadi faktor utama yang mengancam produktivitas jagung. Serangan patogen seperti *Fusarium spp.*, *Puccinia sorghi*, atau *Helminthosporium maydis* dapat menyebabkan penurunan hasil panen yang signifikan, sehingga berpotensi mengganggu ketersediaan pangan dan kestabilan ekonomi petani [7][8].

Untuk menjawab tantangan tersebut, penelitian dalam bidang teknologi dan data science memiliki peran strategis. Salah satunya adalah pengembangan sistem berbasis kecerdasan buatan (AI) untuk mengidentifikasi penyakit pada tanaman jagung secara dini dan akurat. Dengan memanfaatkan citra daun jagung serta teknik machine learning atau deep learning, sistem ini dapat membantu petani dalam melakukan deteksi cepat terhadap gejala penyakit sebelum menyebar luas. Pendekatan ini tidak hanya meningkatkan efisiensi produksi, tetapi juga mendukung tujuan ketahanan pangan global (SDGs poin 2: Zero Hunger) dengan memastikan hasil panen tetap optimal dan berkelanjutan. Dengan demikian, penelitian ini berkontribusi langsung pada upaya menjaga produktivitas jagung sebagai komoditas strategis nasional sekaligus memperkuat sistem ketahanan pangan dunia melalui penerapan inovasi teknologi dalam sektor pertanian. [9][10]. Menurut data dari Food and Agriculture Organization (FAO), produksi jagung menunjukkan tren peningkatan dari tahun 2010 hingga 2018, mencapai 30,25 juta ton pada 2018. Namun, pada 2019 produksi mengalami penurunan sebesar 25% menjadi 22,59 juta ton, dan kembali turun 0,38% pada 2020 menjadi 22,5 juta ton [11]. Salah satu faktor yang menghambat peningkatan produksi jagung adalah serangan organisme pengganggu tanaman. Salah satu kendala dalam meningkatkan produksi jagung adalah adanya berbagai hambatan, termasuk serangan organisme pengganggu tanaman [12] [13]. Berbagai upaya terus dilakukan untuk mencegah dan mengatasi organisme pengganggu tanaman (OPT), termasuk hama dan penyakit pada jagung. Namun, faktor lingkungan seperti cuaca, suhu, dan kelembaban turut berperan dalam mempercepat perkembangan penyakit pada tanaman jagung.

Permasalahan tersebut menjadi tantangan bagi pengembang teknologi informasi untuk menciptakan sistem yang mampu mengatasinya [14]. Diharapkan teknologi informasi dapat menghasilkan sistem yang dapat mengenali penyakit pada tanaman. Dalam teknik pengolahan citra, terdapat metode yang memungkinkan deteksi penyakit pada daun tanaman, sehingga dapat membedakan antara daun yang sehat dan yang terinfeksi. Salah satu metode yang digunakan untuk mengidentifikasi penyakit pada tanaman jagung adalah Convolutional Neural Network (CNN) [15] [16][17].

Convolutional Neural Network (CNN) adalah salah satu algoritma dalam Deep Learning yang dirancang khusus untuk mengolah dan mengenali informasi dari gambar. CNN mampu menerima input berupa gambar dan secara otomatis mengidentifikasi aspek atau objek yang terdapat di dalamnya. Melalui proses pembelajaran, algoritma ini memungkinkan mesin mengenali pola-pola kompleks serta membedakan satu gambar dengan gambar lainnya. Keunggulan utama CNN terletak pada kemampuannya dalam meniru sistem pengenalan citra di korteks visual manusia, sehingga sangat efektif dalam mengolah informasi visual. Dengan kemampuannya yang unggul dalam pengenalan citra, CNN menjadi dasar utama dalam berbagai aplikasi, seperti deteksi objek, klasifikasi gambar, dan pemrosesan citra secara umum [18] [19] [20].

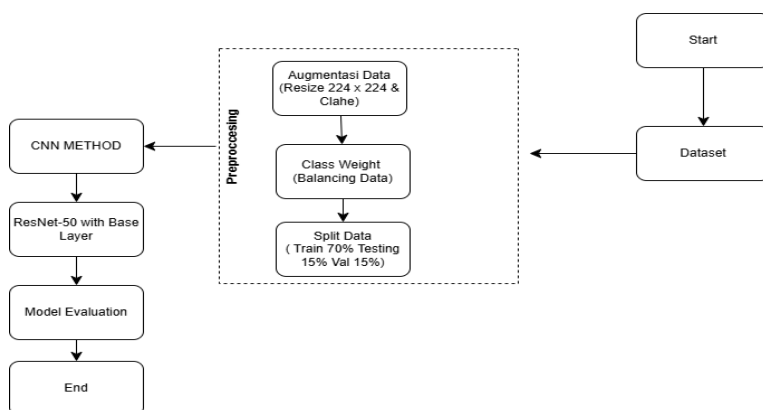
Beberapa penelitian terkait klasifikasi menggunakan CNN telah dilakukan, termasuk studi mengenai penyakit pada tanaman jagung. Data utama diperoleh dari Github, kemudian dikumpulkan dan diklasifikasikan secara manual. Pemrosesan serta analisis data dilakukan dengan menerapkan model dasar CNN serta transfer learning menggunakan VGG16. Hasil implementasi menunjukkan kinerja yang sangat baik, dengan akurasi pelatihan mencapai 98% dan validasi sebesar 97%. Grafik akurasi dan loss memberikan gambaran visual keberhasilan model dalam mendeteksi penyakit. Berdasarkan hasil tersebut, dapat disimpulkan bahwa jaringan saraf konvolusional mampu mengidentifikasi penyakit pada jagung dengan akurasi lebih dari 90% dan dapat diuji dengan berbagai kumpulan data lainnya [21]. Berbeda dengan penelitian dari [22] melakukan klasifikasi citra penyakit daun jagung dengan membandingkan empat model kernel pada Convolutional Neural Network, yaitu  $3 \times 2$ ,  $3 \times 3$ ,  $3 \times 4$ , dan  $4 \times 4$ , serta enam metode optimasi, yakni RMSProp, AdaGrad, SGD, Adam, Adamax, dan Adadelta. Hasil penelitian menunjukkan bahwa metode optimasi Adam dengan kernel  $3 \times 3$  memberikan tingkat akurasi tertinggi, yaitu 84% pada data uji dan 89% pada data latih.

Dalam penelitian [23] dataset yang digunakan diambil dari situs Kaggle dengan judul *Corn or Maize Leaf Disease Dataset*. Dataset ini memiliki 4 klasifikasi, yaitu: Blight, Common Rust, Grey Leaf Spot, dan Healthy. Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan dua model yang berbeda, yaitu algoritma EfficientNet-B0 dan ResNet-50. Arsitektur yang digunakan meliputi *dense layer*, *dropout layer*, dan *GlobalAveragePooling layer*, dengan rasio pembagian dataset sebesar 70% sebagai data pelatihan dan 30% sebagai data validasi. Setelah dilakukan pengujian pada dua skenario model yang diusulkan, hasil akurasi yang diperoleh pada skenario model pertama yaitu EfficientNet-B0 adalah sebesar 94%, sedangkan untuk skenario model kedua yaitu ResNet-50 memperoleh akurasi sebesar 93%. Meskipun begitu, dari grafik *confusion matrix* penelitian ini masih mengalami *overfitting* karena jumlah salah satu kelas dataset yang digunakan tidak seimbang, dan masih terdapat banyak kesalahan pengenalan dalam kelas *Gray leaf spot* yang sering tertukan dengan kelas *blight*.

Untuk mengatasi permasalahan *overfitting* penelitian ini akan menggunakan teknik *Class Balancing* untuk menyeimbangkan jumlah data antara kelas mayoritas dan kelas minoritas dalam dataset agar kelas menjadi seimbang. Dalam *Class Balancing* terdapat teknik *Class Weighting* yang digunakan untuk memberi bobot lebih besar ke kelas *Gray Leaf Spot* karena data dalam kelas ini terhitung minoritas dari kelas lainnya. Model yang digunakan dalam penelitian ini adalah EfficientNet-B0 karena pada penelitian sebelumnya model EfficientNet-B0 memiliki akurasi yang lebih tinggi yaitu sebanyak 94% sedangkan model ResNet-50 hanya menghasilkan akurasi sebanyak 93%. Dataset yang digunakan berasal dari situs Kaggle dengan judul *Corn or Maize Leaf Disease Dataset*. Dataset tersebut terdiri dari 4188 gambar yang terbagi dalam empat kategori, yaitu blight sebanyak 1146 gambar, common rust sebanyak 1306 gambar, gray leaf spot sebanyak 574 gambar, dan healthy sebanyak 1162 gambar.

## II. METODE PENELITIAN

Dapat dilihat pada Gambar 1, proses klasifikasi penyakit daun jagung diawali dengan tahap preprocessing data berupa augmentasi citra berukuran 224×224 piksel serta peningkatan kontras menggunakan Contrast Limited Adaptive Histogram Equalization (CLAHE) untuk memperjelas detail visual daun. Selanjutnya dilakukan penyeimbangan kelas agar distribusi data tiap kategori penyakit seimbang, kemudian dataset dibagi menjadi 70% data pelatihan, 15% data pengujian, dan 15% data validasi. Model dilatih menggunakan Convolutional Neural Network (CNN) dengan arsitektur ResNet-50, yang mampu mengekstraksi fitur mendalam secara efisien melalui mekanisme residual learning. Proses pelatihan dilakukan dengan parameter berupa 50 epoch, batch size 32, dan learning rate 0,001, yang dipilih untuk menjaga kestabilan konvergensi dan mengoptimalkan kinerja model. Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, dan confusion matrix untuk menilai kemampuan model dalam mengklasifikasikan penyakit daun jagung secara tepat, sehingga hasil penelitian ini diharapkan dapat mendukung deteksi dini penyakit tanaman dan memperkuat ketahanan pangan melalui peningkatan produktivitas pertanian.



Gambar 1. Metode Penelitian

### A. Pengumpulan Dataset

Penelitian ini menggunakan data dari layanan penyedia data publik yang dapat diakses oleh siapa saja untuk keperluan penelitian. Sumber data yang digunakan berasal dari situs [www.kaggle.com](http://www.kaggle.com), tepatnya dataset berjudul *Corn or Maize Leaf Disease Dataset* yang dikontribusikan oleh Smaranjit Ghose. Dataset ini

terdiri dari gambar atau citra digital daun jagung dan telah digunakan dalam beberapa penelitian sebelumnya, seperti yang dilakukan oleh dalam penelitian berjudul *Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease*. Serta dalam penelitian yang berjudul *Identifying Types of Corn Leaf Diseases with Deep Learning*. Data yang digunakan dalam penelitian ini diklasifikasikan ke dalam dua kategori, yaitu satu kelas untuk daun sehat dan satu lainnya untuk daun yang terinfeksi penyakit. Dataset yang akan digunakan terbagi menjadi 4 kelas yaitu: *Blight*, *Comon Rust*, *Grey Leaf Spot*, dan *Healthy*. Citra daun dapat dilihat pada Gambar 2.



Gambar 2. Kategori Penyakit Daun Jagung

### B. Pra-Pemrosesan Data

Pra-pemrosesan data merupakan tahap penting dalam penelitian ini untuk memastikan kualitas dataset citra daun jagung yang optimal sebelum digunakan dalam proses pelatihan model klasifikasi. Langkah awal pada pra-pemrosesan adalah augmentasi data, yaitu dengan mengubah ukuran citra menjadi  $224 \times 224$  piksel dan meningkatkan kontras menggunakan teknik *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Teknik ini bertujuan untuk meningkatkan visibilitas fitur-fitur penting pada daun yang terdampak penyakit, terutama dalam kondisi pencahayaan yang kurang optimal.

Selanjutnya dilakukan penyeimbangan distribusi kelas dalam dataset menggunakan pendekatan *class weighting*, guna mengatasi ketidakseimbangan antar kategori penyakit yang dapat menyebabkan bias dalam pembelajaran model. Setelah itu, dataset dibagi menjadi tiga subset utama: 70% data pelatihan, 15% data pengujian, dan 15% data validasi. Proses pembagian ini memastikan bahwa model CNN dengan arsitektur ResNet-50 mendapatkan data pelatihan yang cukup, serta dapat dievaluasi secara obyektif dengan data uji dan validasi yang terpisah. Tahapan ini menjadi fondasi penting untuk membangun model klasifikasi yang akurat dan mampu melakukan generalisasi terhadap data baru secara efektif.

### C. Pengembangan Model

Pengembangan model dalam penelitian ini dilakukan dengan pendekatan *transfer learning* menggunakan arsitektur ResNet-50, yang telah dilatih sebelumnya pada dataset ImageNet. Model dasar ResNet-50 digunakan tanpa lapisan klasifikasi atas, dan dimodifikasi dengan menambahkan beberapa lapisan baru seperti *GlobalAveragePooling*, *dense layer* dengan 128 neuron (aktivasi ReLU), dan *output layer* beraktivasi softmax untuk mengklasifikasikan gambar daun jagung ke dalam empat kelas: *Blight*, *Common Rust*, *Grey Leaf Spot*, dan *Healthy*. Seluruh gambar masukan diubah ukurannya menjadi  $224 \times 224$  piksel sebelum dimasukkan ke dalam model. Model kemudian dikompilasi menggunakan fungsi *categorical crossentropy* dan algoritma optimasi Adam dengan *learning rate* awal  $1e-4$ .

Pada tahap awal pelatihan, semua lapisan pada model dasar dibekukan agar hanya lapisan klasifikasi baru yang dilatih. Setelah beberapa epoch, dilanjutkan ke tahap *fine-tuning* dengan membuka seluruh lapisan ResNet-50 dan menurunkan *learning rate* menjadi  $1e-5$  agar pembaruan bobot lebih halus dan stabil. Proses pelatihan dilakukan menggunakan data yang telah diaugmentasi, serta disertai teknik validasi untuk memantau performa dan mencegah *overfitting*. Strategi ini memungkinkan model memanfaatkan representasi fitur kuat dari ResNet-50 sambil beradaptasi secara optimal terhadap karakteristik citra penyakit daun jagung, sehingga diharapkan menghasilkan klasifikasi yang akurat dan andal dalam berbagai kondisi citra.

### D. Pelatihan Model

Pelatihan model dilakukan menggunakan arsitektur ResNet-50 dengan pendekatan *transfer learning* selama 50 epoch dan batch size 32. Sebelum pelatihan, citra daun jagung diproses melalui tahapan *resize* ke ukuran  $224 \times 224$  piksel dan peningkatan kontras menggunakan metode CLAHE, lalu dibagi menjadi 70% data pelatihan, 15% data

pengujian, dan 15% data validasi. Model dikompilasi dengan fungsi kerugian *categorical crossentropy* dan optimizer Adam, serta dilengkapi dengan mekanisme early stopping untuk mencegah *overfitting*. Strategi ini memungkinkan proses pelatihan berlangsung efisien dengan kemampuan model yang optimal dalam mengenali pola penyakit pada citra daun jagung.

#### E. Evaluasi Model

Pemilihan metrik akurasi, precision, recall, dan F1-score sangat relevan untuk mengevaluasi model klasifikasi penyakit daun jagung berbasis CNN karena setiap metrik memberikan perspektif berbeda terhadap kinerja model. Akurasi menunjukkan seberapa banyak prediksi model yang benar secara keseluruhan, namun metrik ini saja belum cukup ketika distribusi data antar kelas tidak seimbang. Oleh karena itu, precision dan recall digunakan untuk memberikan gambaran yang lebih mendalam. Precision penting karena menunjukkan seberapa andal model dalam memberikan prediksi positif yang benar, sehingga menghindari kesalahan klasifikasi yang dapat menyebabkan tindakan pengendalian penyakit yang tidak perlu. Sementara itu, recall menilai kemampuan model untuk mendeteksi semua daun yang benar-benar terinfeksi, yang sangat penting dalam konteks pertanian agar tidak ada tanaman sakit yang terlewat terdeteksi. F1-score, sebagai rata-rata harmonik antara precision dan recall, menjadi indikator keseimbangan antara keduanya, terutama ketika terdapat trade-off antara tingkat kesalahan positif dan negatif. Dalam kasus identifikasi penyakit daun jagung, kombinasi keempat metrik ini memberikan evaluasi yang komprehensif: akurasi menggambarkan performa global model, precision menyoroti ketepatan klasifikasi, recall menilai sensitivitas deteksi penyakit, dan F1-score memastikan keseimbangan di antara keduanya. adalah sebagai berikut:

$$Presisi = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TN}{TN + TP} \quad (2)$$

$$F1 = \frac{2 \times Presisi \times Recall}{Presisi + Recall} \quad (3)$$

TP mengacu pada True Positives, FP adalah False Positives, dan FN merupakan False Negatives. Untuk memberikan gambaran lebih rinci mengenai kemampuan model dalam membedakan setiap kelas penyakit, digunakan confusion matrix sebagai alat visualisasi. Selain itu, grafik akurasi dan loss juga disertakan guna menunjukkan perubahan kinerja model selama proses pelatihan berlangsung. Nilai akurasi (A) dihitung untuk mengevaluasi seberapa tepat prediksi model terhadap data yang diberikan. Akurasi dihitung sebagai:

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

Proses evaluasi memberikan hasil numerik yang rinci, memungkinkan analisis yang lebih mendalam terhadap kekuatan dan kelemahan klasifikasi yang dilakukan.

### III. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan mengembangkan model untuk identifikasi penyakit pada daun jagung dengan memanfaatkan pendekatan transfer learning menggunakan arsitektur **ResNet50**. Evaluasi terhadap model menunjukkan kinerja yang sangat baik berdasarkan metrik precision, recall, f1-score, dan akurasi total. Selain itu, analisis juga dilakukan melalui confusion matrix dan visualisasi nilai kehilangan (loss) selama proses pelatihan guna memastikan kualitas model yang dihasilkan.

#### A. Evaluasi Kinerja Model

Berdasarkan Tabel 1, model CNN yang digunakan untuk identifikasi penyakit tanaman jagung menunjukkan performa yang sangat baik dengan akurasi keseluruhan sebesar 94%. Kinerja tiap kelas penyakit menunjukkan bahwa model mampu

mengenali kelas Healthy dengan sangat baik (Presisi, Recall, dan F1-Score = 1.00), serta Common Rust dengan performa hampir sempurna (F1-Score = 0.98). Hal ini mengindikasikan bahwa fitur visual daun sehat dan penyakit Common Rust memiliki pola yang cukup konsisten dan mudah dikenali oleh model. Sementara itu, kelas Blight juga terdeteksi dengan baik (F1-Score = 0.90), menunjukkan kemampuan model yang stabil dalam mengklasifikasi daun yang terinfeksi Blight.

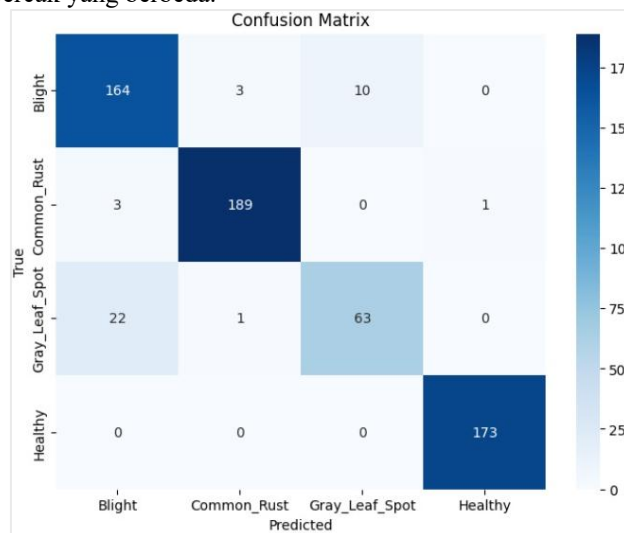
TABEL I.  
 EVALUASI KINERJA MODEL

Penyakit	Presisi	Recall	F1-Score	Support
Blight	0.87	0.93	0.90	177
Common_Rust	0.98	0.98	0.98	193
Gray Leaf Spot	0.86	0.73	0.79	86
Healthy	0.99	1.00	1.00	173
<b>Accuracy</b>			<b>0.94</b>	<b>629</b>
Macro avg	0.93	0.91	0.92	629
Weighted avg	0.94	0.94	0.94	629

Namun, performa pada kelas Gray Leaf Spot relatif lebih rendah dengan nilai F1-Score hanya 0.79, terutama karena nilai recall yang menurun (0.73), menandakan bahwa beberapa citra Gray Leaf Spot masih sering salah diklasifikasikan sebagai kelas lain. Meski demikian, nilai rata-rata makro dan tertimbang (macro avg dan weighted avg) yang sama-sama mencapai sekitar 0.92–0.94 memperlihatkan bahwa model bekerja konsisten di semua kelas tanpa bias besar terhadap jumlah data per kelas. Secara keseluruhan, hasil ini membuktikan bahwa arsitektur CNN yang digunakan efektif untuk mendeteksi dan mengklasifikasikan penyakit daun jagung dari citra secara akurat.

### B. Analisis Confusion Matrix

Berdasarkan confusion matrix pada Gambar 3, model CNN menunjukkan performa klasifikasi yang sangat baik pada sebagian besar kelas penyakit tanaman jagung. Kelas **Healthy** diklasifikasikan dengan sempurna tanpa kesalahan (173 citra terdeteksi benar), dan kelas **Common Rust** juga memiliki akurasi tinggi dengan 189 citra teridentifikasi benar dari total 193, hanya terdapat sedikit kesalahan klasifikasi ke kelas Blight dan Healthy. Kinerja yang baik pada kedua kelas ini menunjukkan bahwa model mampu menangkap ciri visual yang khas dari daun jagung sehat dan yang terinfeksi Common Rust, seperti warna dan pola bercak yang berbeda.



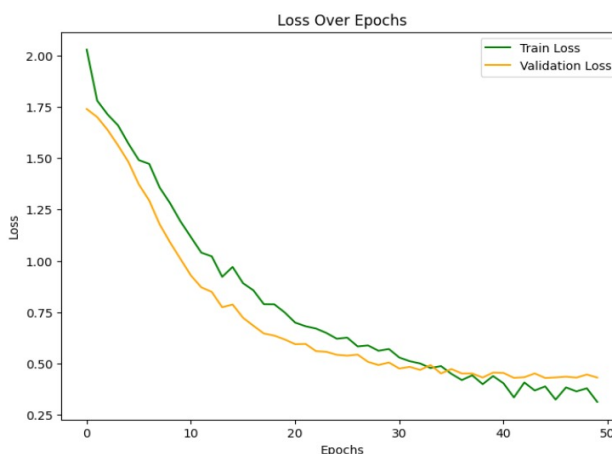
Gambar 3. Confusion Matrix

Sementara itu, kelas **Blight** juga terdeteksi cukup baik dengan 164 dari 177 citra terklasifikasi benar, namun masih terdapat beberapa salah klasifikasi ke kelas Gray Leaf Spot. Kesalahan paling menonjol terjadi pada kelas **Gray Leaf Spot**, di mana 22 citra justru diklasifikasikan sebagai Blight. Hal ini menunjukkan bahwa karakteristik visual antara kedua penyakit tersebut cenderung mirip, sehingga model masih mengalami kesulitan dalam membedakannya secara konsisten. Meski begitu, secara keseluruhan matriks ini memperlihatkan bahwa model CNN mampu melakukan identifikasi penyakit daun jagung dengan tingkat akurasi tinggi dan kesalahan klasifikasi yang relatif kecil.

### C. Proses Pelatihan Model

Grafik *Loss Over Epochs* pada Gambar 4, menunjukkan tren penurunan nilai *loss* pada data latih dan validasi selama proses pelatihan model CNN untuk identifikasi penyakit tanaman jagung berdasarkan citra daun. Pada awal

pelatihan (epoch 0–10), terlihat penurunan tajam pada kedua kurva, menandakan bahwa model dengan cepat mempelajari pola dasar dari data citra. Seiring bertambahnya epoch, penurunan *loss* menjadi lebih lambat dan stabil, menunjukkan bahwa model mulai mencapai titik konvergensi dan pembelajaran berjalan efektif. Nilai *validation loss* yang selalu lebih rendah atau mendekati *train loss* juga menandakan bahwa model memiliki generalisasi yang baik terhadap data baru.



Gambar 4. Grafik Loss

Pada sekitar epoch ke-30 hingga ke-50, *loss* cenderung stabil di kisaran 0.25–0.35, baik untuk data latih maupun validasi, yang berarti model sudah tidak mengalami *overfitting* maupun *underfitting*. Hal ini menunjukkan keseimbangan antara kemampuan model dalam mempelajari fitur visual daun yang kompleks dan kemampuannya untuk mempertahankan performa pada data yang tidak pernah dilihat sebelumnya. Secara keseluruhan, grafik ini mengindikasikan bahwa proses pelatihan CNN berlangsung optimal dan model berhasil mencapai performa yang konvergen dalam mengidentifikasi berbagai jenis penyakit daun jagung. Penelitian ini dilakukan untuk mengatasi beberapa kelemahan pada penelitian sebelumnya. Untuk mengoptimalkan CNN yang digunakan memerlukan waktu komputasi yang signifikan. Penelitian ini menggunakan ResNet-50 dengan base layer yang lebih efisien dari segi pelatihan. Pada penelitian sebelumnya menggunakan dataset yang sama dengan penelitian ini namun masih berpotensi mengalami *overfitting* dan keterbatasan generalisasi. Penelitian ini mengatasi masalah tersebut dengan menggunakan dataset yang sama namun hanya menggunakan arsitektur ResNet-50 dengan menambahkan proses augmentasi CLAHE dan resize.

Hasil yang diperoleh menunjukkan potensi besar penggunaan Model CNN dengan arsitektur ResNet-50 untuk identifikasi penyakit pada tanaman jagung berdasarkan citra daun. Dengan akurasi keseluruhan sebesar 94%, dimana model ResNet-50 dengan base layer serta metode preprocessing menggunakan CLAHE dan resize terbukti menghasilkan akurasi yang lebih tinggi dari penelitian sebelumnya yang hanya mendapatkan akurasi sebesar 93%. Penelitian oleh [24] juga menggunakan model ResNet-50 dengan menambahkan augmentasi CLAHE dan mencapai akurasi sebesar 95,05% hasil pada penelitian ini menunjukkan bahwa model ResNet-50 memiliki performa yang baik. Sedangkan pada penelitian [25] juga menggunakan model ResNet-50 untuk klasifikasi penyakit mata, penelitian ini menghasilkan akurasi tertinggi sebesar 64,60% hasil ini kurang optimal karena dataset yang digunakan sangat minim serta tidak menambahkan proses augmentasi apapun.

#### IV. KESIMPULAN

Berdasarkan hasil pelatihan menggunakan 629 data gambar daun jagung dan penerapan metode transfer learning pada arsitektur ResNet-50, model menunjukkan performa yang sangat baik dengan akurasi keseluruhan sebesar 94%. Nilai presisi, recall, dan skor F1 yang diperoleh pada setiap kategori penyakit juga tinggi, dengan rata-rata presisi dan recall di atas 0,91 untuk sebagian besar kelas. Kategori Healthy memiliki performa terbaik dengan nilai presisi, recall, dan skor F1 sebesar 1,00, sedangkan kategori Gray Leaf Spot memiliki nilai skor F1 terendah yaitu 0,79, kemungkinan karena kemiripannya dengan gejala penyakit lain seperti Blight atau Common Rust. Meskipun terdapat kesalahan klasifikasi kecil, hasil penelitian ini menunjukkan bahwa model sangat efektif dalam mengklasifikasikan penyakit daun jagung. Secara keseluruhan, model ini dapat diandalkan untuk aplikasi praktis deteksi penyakit daun jagung berbasis citra, dan berpotensi mendukung pengembangan teknologi pertanian cerdas yang lebih akurat dan efisien. Meskipun model ResNet-50 menunjukkan performa yang tinggi dalam mengidentifikasi penyakit pada daun jagung dengan akurasi mencapai 94%, terdapat beberapa kelemahan potensial yang perlu diperhatikan terkait penggunaan algoritma dan metode yang diterapkan. Pertama, model berbasis deep

learning seperti ResNet-50 memerlukan sumber daya komputasi yang besar, baik dari segi waktu pelatihan maupun kebutuhan perangkat keras (GPU) untuk mencapai hasil optimal, sehingga kurang efisien jika diterapkan pada lingkungan dengan keterbatasan infrastruktur. Kedua, meskipun proses augmentasi citra dan CLAHE membantu meningkatkan kualitas data serta mengurangi risiko overfitting, metode ini tidak sepenuhnya menjamin ketahanan model terhadap variasi citra di dunia nyata, seperti perbedaan pencahayaan, sudut pengambilan gambar, atau kondisi daun yang tidak ideal. Selain itu, akurasi tinggi tidak selalu mencerminkan kemampuan generalisasi model, terutama jika dataset pelatihan tidak cukup beragam atau tidak mewakili seluruh kondisi penyakit yang mungkin muncul di lapangan. Kelemahan lainnya adalah model masih bersifat "black box", sehingga sulit untuk menjelaskan secara transparan alasan di balik keputusan klasifikasinya. Oleh karena itu, penelitian lanjutan dapat mempertimbangkan penggunaan metode explainable AI (XAI), perluasan dataset lapangan, atau integrasi dengan teknik transfer learning adaptif guna meningkatkan interpretabilitas dan generalisasi model dalam mendukung sistem deteksi penyakit tanaman yang lebih andal.

## V. DAFTAR PUSTAKA

- [1] S. Panikkai, M. Azrai, and F. N. Fahmi, "Model production of corn development for industrial needs and increasing economy," *IOP Conf Ser Earth Environ Sci*, vol. 484, no. 1, p. 012137, Apr. 2020, doi: 10.1088/1755-1315/484/1/012137.
- [2] D. Iswanto and D. Handayani UN, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Ilmiah Universitas Batanghari Jambi*, vol. 22, no. 2, p. 900, Jul. 2022, doi: 10.33087/jjub.v22i2.2065.
- [3] A. J., J. Eunice, D. E. Popescu, M. K. Chowdary, and J. Hemanth, "Deep Learning-Based Leaf Disease Detection in Crops Using Images for Agricultural Applications," *Agronomy*, vol. 12, no. 10, p. 2395, Oct. 2022, doi: 10.3390/agronomy12102395.
- [4] S. del C. Mina and J. D. Quintana-Garrido, "Corn as an alternative method for contributing to the country's public policies in terms of health, sustainable economy and food security, accordance with the 2030 Agenda and FAO," *Journal Law and Economy*, vol. 8, no. 14, Dec. 2024, doi: 10.35429/JLE.2024.8.14.1.10.
- [5] B. Yang, S. Wu, and Z. Yan, "Effects of Climate Change on Corn Yields: Spatiotemporal Evidence from Geographically and Temporally Weighted Regression Model," *ISPRS Int J Geoinf*, vol. 11, no. 8, p. 433, Aug. 2022, doi: 10.3390/ijgi11080433.
- [6] Z. Ma, W. Wang, X. Chen, K. Gehman, H. Yang, and Y. Yang, "Prediction of the global occurrence of maize diseases and estimation of yield loss under climate change," *Pest Manag Sci*, vol. 80, no. 11, pp. 5759–5770, Nov. 2024, doi: 10.1002/ps.8309.
- [7] E. E. Rezaei *et al.*, "Climate change impacts on crop yields," *Nat Rev Earth Environ*, vol. 4, no. 12, pp. 831–846, Nov. 2023, doi: 10.1038/s43017-023-00491-0.
- [8] "Prediksi kejadian penyakit jagung global dan estimasi kehilangan hasil panen akibat perubahan iklim".
- [9] M. Adha, E. Utami, and H. Hanafi, "PREDIKSI PRODUKSI JAGUNG MENGGUNAKAN ALGORITMA APRIORI DAN REGRESI LINEAR BERGANDA (STUDI KASUS : DINAS PERTANIAN KABUPATEN DOMPU)," *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 3, pp. 803–820, Aug. 2022, doi: 10.29100/jipi.v7i3.3139.
- [10] Asifha Defitrian Salsabila, Solfema Solfema, and Lili Dasa Putri, "Pengolahan Hasil Pertanian Jagung untuk Meningkatkan Perekonomian Desa," *Harmoni Pendidikan : Jurnal Ilmu Pendidikan*, vol. 2, no. 1, pp. 192–200, Dec. 2024, doi: 10.62383/hardik.v2i1.1055.
- [11] D. S. Mueller *et al.*, "Corn Yield Loss Estimates Due to Diseases in the United States and Ontario, Canada, from 2016 to 2019," *Plant Health Prog*, vol. 21, no. 4, pp. 238–247, Jan. 2020, doi: 10.1094/PHP-05-20-0038-RS.
- [12] M. Sime, S. Ballo, Z. Abro, D. A. Gugissa, E. Mendesil, and T. Tefera, "Farmers' Perceptions of Maize Production Constraints and the Effects of Push–Pull Technology on Soil Fertility, Pest Infestation, and Maize Yield in Southwest Ethiopia," *Agriculture*, vol. 14, no. 3, p. 381, Feb. 2024, doi: 10.3390/agriculture14030381.
- [13] D. T. Chirinos *et al.*, "Entomofauna Associated with Corn Cultivation and Damage Caused by Some Pests According to the Planting Season on the Ecuadorian Coast," *Agronomy*, vol. 14, no. 4, p. 748, Apr. 2024, doi: 10.3390/agronomy14040748.
- [14] Y. Permanasari, B. N. Ruchjana, S. Hadi, and J. Rejito, "Innovative Region Convolutional Neural Network Algorithm for Object Identification," *Journal of Open Innovation: Technology, Market, and Complexity*, vol. 8, no. 4, p. 182, Dec. 2022, doi: 10.3390/joitmc8040182.
- [15] J. Agarwal, S. Naithani, U. Singh, and H. Raj, "Plant Disease Detection using Convolutional Neural Network," in *2023 International Conference on Smart Devices (ICSD)*, IEEE, May 2024, pp. 1–5. doi: 10.1109/ICSD60021.2024.10751329.
- [16] A. Waheed, M. Goyal, D. Gupta, A. Khanna, A. E. Hassanien, and H. M. Pandey, "An optimized dense convolutional neural network model for disease recognition and classification in corn leaf," *Comput Electron Agric*, vol. 175, p. 105456, Aug. 2020, doi: 10.1016/j.compag.2020.105456.
- [17] M. Syarif and W. Setiawan, "Convolutional neural network for maize leaf disease image classification," *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 18, no. 3, p. 1376, Jun. 2020, doi: 10.12928/telkomnika.v18i3.14840.
- [18] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, "Review of Image Classification Algorithms Based on Convolutional Neural Networks," *Remote Sens (Basel)*, vol. 13, no. 22, p. 4712, Nov. 2021, doi: 10.3390/rs13224712.
- [19] V. N. S. S. Chimakurthi, "Application of Convolution Neural Network for Digital Image Processing," *Engineering International*, vol. 8, no. 2, pp. 149–xxx, Dec. 2020, doi: 10.18034/ei.v8i2.592.
- [20] M. Mustakim, A. R. Pratama, I. Ahmad, T. Arifianto, K. Sussolaikah, and S. Sepriano, "Image Classification of Corn Leaf Diseases Using CNN Architecture ResNet-50 and Data Augmentation," in *2024 International Conference on Decision Aid Sciences and Applications (DASA)*, IEEE, Dec. 2024, pp. 1–6. doi: 10.1109/DASA63652.2024.10836354.
- [21] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *sudo Jurnal Teknik Informatika*, vol. 2, no. 1, pp. 28–33, Feb. 2023, doi: 10.56211/sudo.v2i1.227.
- [22] A. D. Nurcahyati, R. M. Akbar, and S. Zahara, "Klasifikasi Citra Penyakit pada Daun Jagung Menggunakan Deep Learning dengan Metode Convolution Neural Network (CNN)," *SUBMIT: Jurnal Ilmiah Teknologi Informasi dan Sains*, vol. 2, no. 2, pp. 43–51, Jun. 2022, doi: 10.36815/submit.v2i2.1877.
- [23] 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 (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 326–333, Mar. 2023, doi: 10.29207/resti.v7i2.4736.
- [24] N. D. Miranda, L. Novamizanti, and S. Rizal, "CONVOLUTIONAL NEURAL NETWORK PADA KLASIFIKASI SIDIK JARI MENGGUNAKAN RESNET-50," *Jurnal Teknik Informatika (Jutif)*, vol. 1, no. 2, pp. 61–68, Dec. 2020, doi: 10.20884/1.jutif.2020.1.2.18.
- [25] E. Hartati, "KLASIFIKASI PENYAKIT MATA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK MODEL RESNET-50."