

Optimasi Deteksi Penyakit Daun Jagung Menggunakan Transfer Learning MobileNetV2 Berbasis Citra Digital

Muhammad Hamdi^{1*}, Hairani², Muhammad Farizal³

Universitas Bumigora, mataram, Indonesia

Article Info

Article history:

Received mm dd, yyyy

Revised mm dd, yyyy

Accepted mm dd, yyyy

Keywords:

MobileNetV2,
Deep Learning,
Transfer Learning,
Klasifikasi Citra,
Penyakit Daun Jagung,
Smart Agriculture

ABSTRACT

Penyakit daun jagung merupakan salah satu faktor utama yang menyebabkan penurunan produktivitas tanaman jagung karena dapat menghambat proses fotosintesis dan pertumbuhan tanaman. Identifikasi penyakit secara manual memerlukan keahlian khusus serta waktu yang relatif lama sehingga kurang efektif untuk pemantauan skala luas. Penelitian ini bertujuan mengembangkan model klasifikasi penyakit daun jagung berbasis *Deep Learning* menggunakan arsitektur MobileNetV2 dengan pendekatan *transfer learning* dan *fine-tuning*. Dataset yang digunakan terdiri atas citra daun jagung yang dikelompokkan ke dalam tiga kelas, yaitu Hawar Daun (*Blight*), Karat Daun (*Rust*), dan Daun Sehat (*Healthy*). Tahap penelitian meliputi prapemrosesan citra, normalisasi menggunakan *preprocess_input*, augmentasi data, pelatihan model, *fine-tuning*, serta evaluasi menggunakan metrik Accuracy, Precision, Recall, dan F1-Score. MobileNetV2 dipilih karena memiliki kompleksitas komputasi yang rendah namun tetap mampu menghasilkan performa klasifikasi yang baik. Hasil penelitian menunjukkan bahwa kombinasi augmentasi data, transfer learning, dan *fine-tuning* mampu meningkatkan kemampuan model dalam mengenali karakteristik penyakit daun jagung secara efektif. Model yang dihasilkan memiliki potensi untuk diterapkan pada sistem pertanian cerdas (*smart agriculture*) sebagai alat bantu deteksi dini penyakit tanaman secara cepat, akurat, dan efisien.

This is an open access article under the [CC BY-SA](#) license.



Corresponding Author:

Muhammad Hamdi,
Universitas Bumigora, Mataram, Indonesia.
Email: bagloncity@gmail.com.

Cara Mengutip: nama, tahun, “Analisis Sentimen dan Pemodelan Topik Aplikasi Kitabisa menggunakan Support Vector Machine (SVM) dan Metode Tautan Smote-Tomek”, **Journal of Smart Computing and Digital Transformation**, vol. 2, no. 2, hlm. 81 - 91, Sep. 2023. doi : [10.30812/ vertex.v0i0.000](https://doi.org/10.30812/vertex.v0i0.000).

1 INTRODUCTION

Jagung (*Zea mays* L.) merupakan salah satu komoditas tanaman pangan strategis di Indonesia yang memegang peran vital dalam ketahanan pangan nasional, pakan ternak, dan industri pengolahan. Berdasarkan data Badan Pusat Statistik [1], luas panen jagung pipilan di Indonesia pada tahun 2024 mencapai 2,55 juta hektare. Meskipun demikian, produksi jagung mengalami tekanan serius akibat serangan organisme pengganggu tanaman (OPT), khususnya penyakit pada daun. Menurut catatan [2], serangan hama dan penyakit pada tanaman jagung sering menjadi penyebab utama rendahnya hasil produksi di berbagai daerah di Indonesia.

Beberapa penyakit daun jagung yang paling merusak meliputi *Northern Leaf Blight* (*Hawar Daun Utara*), *Common Rust* (*Karat Daun*), dan *Gray Leaf Spot* (*Bercak Daun Abu-abu*). Hasil pengamatan lapangan di Provinsi Sumatera menunjukkan bahwa intensitas serangan penyakit karat daun dapat mencapai 76–92% pada berbagai varietas jagung [3], sementara penyakit bulai (*downy mildew*) berpotensi menyebabkan kehilangan hasil hingga 100% pada varietas yang rentan [4]. Deteksi dini terhadap jenis-jenis penyakit ini menjadi kunci utama dalam upaya pengendalian yang tepat dan efisien.

Praktik diagnosis penyakit daun jagung yang masih dominan dilakukan secara manual oleh petani dan petugas pertanian menghadapi berbagai keterbatasan mendasar. Metode konvensional ini bersifat subjektif, membutuhkan keahlian agronomis yang mendalam, rentan terhadap kesalahan identifikasi, dan tidak skalabel untuk pemantauan lahan dalam skala besar. Dalam kondisi lapangan nyata, faktor pencahayaan yang bervariasi, latar belakang gambar yang kompleks, serta kemiripan visual antargejala penyakit semakin mempersulit diagnosis akurat. Kondisi inilah yang membentuk gap fenomena yang mendesak untuk diatasi melalui pendekatan otomasi berbasis kecerdasan buatan.

Perkembangan teknologi *deep learning* telah membuka peluang besar dalam otomasi deteksi penyakit tanaman berbasis citra digital. Berbagai arsitektur *Convolutional Neural Network* (CNN) telah diuji coba untuk klasifikasi penyakit daun jagung, mulai dari VGG, ResNet, EfficientNet, hingga model-model ringan (*lightweight*) yang berorientasi pada efisiensi komputasi. [5] mengembangkan sistem multi-tugas berbasis MobileNetV3Large dengan akurasi 94,44% pada dataset penyakit daun jagung, sementara [6] mendemonstrasikan bahwa MobileNetV2 yang diperkaya dengan augmentasi fitur mampu mengklasifikasikan penyakit benih jagung dengan dataset 21.662 citra.

Namun, kajian sistematis terhadap literatur terkini mengidentifikasi sejumlah gap penelitian yang signifikan. Pertama, sebagian besar studi menggunakan dataset yang dikumpulkan dalam kondisi laboratorium terkontrol, sehingga performa model menurun drastis ketika diuji pada citra lapangan nyata dengan variasi pencahayaan, sudut pengambilan, dan latar belakang yang kompleks [7];[8]. Kedua, banyak model CNN konvensional yang diusulkan memiliki jumlah parameter besar dan kebutuhan komputasi tinggi, sehingga tidak praktis untuk diimplementasikan pada perangkat *edge* atau smartphone yang banyak digunakan oleh petani di negara berkembang seperti Indonesia [9].

Ketiga, riset terdahulu umumnya belum mengeksplorasi strategi optimasi MobileNetV2 secara komprehensif, terutama dalam hal *fine-tuning* lapisan-lapisan kritis, penyesuaian *learning rate*, teknik regularisasi (*dropout*), dan kombinasi strategi augmentasi data yang tepat sasaran [10];[11]. Keempat, tinjauan komprehensif oleh BioData Mining (2025) mengungkap bahwa dataset penyakit daun tanaman yang tersedia umumnya tidak seimbang (*imbalanced*), mencakup wilayah geografis yang sempit, dan memiliki masalah inkonsistensi anotasi, sehingga generalisasi model lintas kondisi agroekologi masih menjadi tantangan terbuka. Kelima, aspek interpretabilitas model atau *explainable AI* (XAI) yang penting bagi kepercayaan pengguna di lapangan masih jarang diintegrasikan dalam sistem deteksi penyakit daun jagung berbasis MobileNetV2 [9].

Tinjauan literatur sistematis terbaru juga mengidentifikasi bahwa meskipun kemajuan AI dalam klasifikasi penyakit tanaman cukup pesat, tantangan berupa keterbatasan generalisasi, dataset yang kecil dan tidak seimbang, serta performa yang buruk pada kondisi dunia nyata masih terus menjadi hambatan utama (PMC Review, 2025). Kondisi gap penelitian ini

memperkuat urgensi untuk melakukan studi optimasi yang terfokus pada MobileNetV2 dengan pendekatan transfer learning yang lebih sistematis dan terstruktur.

Urgensi penelitian ini bersumber dari tiga dimensi yang saling berkaitan. Dari dimensi pertanian, penurunan produksi jagung nasional dari tahun ke tahun akibat gangguan hama dan penyakit sebagaimana tercatat dalam data BPS (2023) yang menunjukkan produksi jagung turun menjadi 12.928.940 ton pada 2023 membutuhkan solusi deteksi dini yang handal dan dapat diakses oleh petani. Keterlambatan dalam identifikasi penyakit berdampak langsung pada kehilangan hasil panen yang berujung pada kerugian ekonomi petani dan ancaman terhadap ketahanan pangan nasional.

Dari dimensi teknologi, MobileNetV2 merupakan arsitektur CNN yang dirancang khusus untuk efisiensi komputasi dengan struktur *inverted residual* dan *linear bottleneck*, menjadikannya kandidat ideal untuk sistem deteksi yang dapat berjalan pada perangkat dengan sumber daya terbatas [12]. Namun, potensi arsitektur ini dalam skenario deteksi penyakit daun jagung belum dieksplorasi secara optimal khususnya dalam konteks agroekologi Indonesia yang memiliki karakteristik iklim, varietas jagung, dan kondisi lahan yang berbeda dari dataset benchmark internasional.

Dari dimensi keterjangkauan dan keberlanjutan, pengembangan sistem deteksi berbasis citra digital dengan model ringan yang teroptimasi memungkinkan integrasi langsung ke aplikasi mobile, mendukung agenda pertanian presisi (*precision agriculture*) yang saat ini diprioritaskan dalam kebijakan ketahanan pangan Indonesia. Penelitian oleh [5] juga telah membuktikan bahwa integrasi model deteksi penyakit jagung ke dalam aplikasi mobile menggunakan *framework* Qt adalah hal yang layak secara teknis, membuka jalan bagi implementasi nyata di tingkat petani.

Berdasarkan analisis gap fenomena dan gap penelitian di atas, penelitian ini menawarkan kebaharuan (*novelty*) pada beberapa aspek berikut:

1. Strategi Optimasi MobileNetV2 yang Komprehensif dan Sistematis

Berbeda dengan penelitian terdahulu yang umumnya menerapkan MobileNetV2 secara *out-of-the-box* atau dengan modifikasi minimal, penelitian ini mengusulkan strategi optimasi yang komprehensif meliputi seleksi lapisan *fine-tuning* yang adaptif, penjadwalan *learning rate* dinamis (*cosine annealing*), kombinasi augmentasi data kontekstual berbasis kondisi lapangan Indonesia, dan regularisasi terstruktur untuk mengatasi ketidakseimbangan kelas. Pendekatan ini belum pernah dilaporkan secara terintegrasi dalam literatur deteksi penyakit daun jagung berbasis MobileNetV2.

2. Adaptasi Kontekstual untuk Agroekologi Indonesia

Penelitian ini secara khusus mempertimbangkan kondisi lapangan di wilayah Indonesia, termasuk variasi intensitas cahaya tropis, karakteristik visual penyakit jagung yang bersifat lokal (seperti penyakit karat *Puccinia polysora* yang dominan di iklim tropis), dan penggunaan dataset yang diperkaya dengan citra dari kondisi lapangan Indonesia. Aspek kontekstualisasi lokal ini merupakan kontribusi yang membedakan penelitian ini dari studi-studi serupa yang berbasis dataset internasional seperti PlantVillage.

3. Evaluasi Performa Komprehensif dengan Pendekatan Explainability

Penelitian ini mengintegrasikan evaluasi performa model yang tidak hanya mengukur akurasi klasifikasi, tetapi juga menyertakan analisis *Grad-CAM* (*Gradient-weighted Class Activation Mapping*) sebagai mekanisme *explainable AI* untuk memvisualisasikan area daun yang berkontribusi pada keputusan klasifikasi model. Langkah ini meningkatkan interpretabilitas dan kepercayaan terhadap sistem, yang merupakan aspek kritis namun sering diabaikan dalam pengembangan sistem deteksi penyakit tanaman [9].

4. Perbandingan Kinerja Sistematis Antar Strategi Transfer Learning

Penelitian ini melakukan analisis komparatif yang sistematis antara beberapa skenario *transfer learning*: (a) *feature extraction* tanpa pembekuan lapisan, (b) *fine-tuning* sebagian lapisan, dan (c) *full fine-tuning*. Perbandingan ini menghasilkan


panduan praktis mengenai skenario optimasi yang paling efektif untuk deteksi penyakit daun jagung, yang dapat menjadi referensi bagi peneliti dan praktisi di bidang pertanian presisi dan kecerdasan komputasional.

Dengan demikian, penelitian ini diharapkan dapat menghasilkan model deteksi penyakit daun jagung yang tidak hanya akurat, tetapi juga efisien secara komputasi, dapat diinterpretasi, dan relevan dengan kondisi pertanian jagung di Indonesia, sehingga berkontribusi nyata pada upaya peningkatan produktivitas dan ketahanan pangan nasional.

2 RESEARCH METHOD

Penelitian ini menggunakan pendekatan Deep Learning berbasis Transfer Learning dengan arsitektur MobileNetV2 untuk melakukan klasifikasi penyakit pada daun jagung. Metode transfer learning dipilih karena mampu memanfaatkan bobot hasil pelatihan pada dataset berskala besar sehingga dapat meningkatkan performa klasifikasi meskipun jumlah data pelatihan relatif terbatas [13]. Tahapan penelitian meliputi pengumpulan dataset, prapemrosesan data, augmentasi citra, pembangunan model MobileNetV2, pelatihan model, fine-tuning, evaluasi performa, serta penyimpanan model akhir. Dataset yang digunakan berasal dari platform Kaggle dengan alamat:

<https://www.kaggle.com/datasets/taufiqnoviant/daun-jagung/data>. Dataset terdiri atas citra daun jagung yang terbagi ke dalam tiga kelas, yaitu: Hawar Daun (Blight), Karat Daun (Rust) dan Daun Sehat (Healthy) sesuai pada gambar 1.



Gambar 1. visualisasi jenis gambar sesuai kategori daun

Berdasarkan kategori daun pada gambar 1, proses selanjutnya adalah melakukan pembagian data menggunakan mekanisme validasi internal, diperoleh mekanisme validasi internal meliputi:; training berjumlah 249 citra, validasi berjumlah 61 citra, testing berjumlah 61 citra dengan total 310 citra daun. Dari total 310 citra, sebanyak 249 citra (80%) digunakan sebagai data training untuk melatih model dalam mengenali pola dan karakteristik penyakit pada daun jagung. Selanjutnya, 61 citra (20%) digunakan sebagai data validation yang berfungsi untuk mengevaluasi kinerja model selama proses pelatihan, sehingga dapat membantu dalam pemantauan proses pembelajaran model dan mencegah terjadinya overfitting.

Setelah model mencapai performa terbaik berdasarkan hasil validasi, dilakukan pengujian menggunakan 61 citra testing yang tidak terlibat dalam proses pelatihan maupun validasi. Data testing digunakan untuk mengukur kemampuan generalisasi model terhadap data baru yang belum pernah dilihat sebelumnya. Dengan mekanisme validasi internal ini, proses pengembangan model dapat dilakukan secara lebih terstruktur sehingga menghasilkan evaluasi performa yang lebih objektif dan reliabel. Pembagian data menjadi training, validation, dan testing juga memastikan bahwa model yang dihasilkan memiliki kemampuan klasifikasi yang baik serta mampu diterapkan pada data nyata di luar dataset pelatihan.

Sebelum proses pelatihan dilakukan, seluruh citra melalui tahapan prapemrosesan menggunakan fungsi `preprocess_input()` dari MobileNetV2 untuk menyesuaikan distribusi nilai piksel dengan model pelatihan. Ukuran citra

diseragamkan menjadi: $224 \times 224 \times 3$ sesuai dengan spesifikasi input MobileNetV2 Untuk meningkatkan keragaman data dan mengurangi risiko overfitting, diterapkan teknik augmentasi data pada tabel 1:

Tabel 1. Teknik augmentasi data

Teknik Augmentasi	Nilai Parameter
Rotation	30°
Zoom	20%
Width Shift	20%
Height Shift	20%
Horizontal Flip	Ya
Fill Mode	Nearest

Tabel 1 menunjukkan teknik augmentasi data yang diterapkan pada citra daun jagung untuk meningkatkan variasi data pelatihan dan memperkuat kemampuan generalisasi model. Augmentasi dilakukan dengan memodifikasi citra secara otomatis tanpa mengubah karakteristik utama objek yang akan diklasifikasikan. Teknik rotation diterapkan dengan sudut maksimum 30°, sehingga citra dapat diputar ke berbagai arah untuk mensimulasikan variasi posisi daun saat proses pengambilan gambar. Selanjutnya, teknik zoom sebesar 20% digunakan untuk menghasilkan variasi ukuran objek dalam citra, sehingga model mampu mengenali pola penyakit pada berbagai skala.

Teknik width shift dan height shift masing-masing sebesar 20% diterapkan untuk menggeser posisi objek secara horizontal maupun vertikal. Transformasi ini membantu model menjadi lebih robust terhadap perubahan letak daun pada gambar. Selain itu, digunakan horizontal flip, yaitu pembalikan citra secara horizontal, untuk menambah variasi orientasi daun yang mungkin ditemukan pada kondisi lapangan.

Pada proses augmentasi, metode fill mode nearest digunakan untuk mengisi area kosong yang muncul akibat transformasi geometris seperti rotasi dan pergeseran. Metode ini bekerja dengan mengisi piksel kosong menggunakan nilai piksel terdekat sehingga kualitas citra tetap terjaga dan tidak menimbulkan artefak yang dapat mengganggu proses pembelajaran model. Penerapan kombinasi teknik augmentasi tersebut bertujuan untuk memperkaya variasi data pelatihan, mengurangi risiko overfitting, serta meningkatkan kemampuan model dalam mengenali penyakit daun jagung pada berbagai kondisi pencahayaan, posisi, dan orientasi citra yang berbeda. Dengan demikian, model diharapkan memiliki performa yang lebih stabil dan akurat ketika diimplementasikan pada data baru di lingkungan nyata.

Penelitian ini menggunakan model MobileNetV2 sebagai feature extractor utama. Model dasar diperoleh dari bobot prelatih ImageNet dengan konfigurasi: Weights = ImageNet, Include Top = False dan Input Shape = (224,224,3). Pada tahap awal, seluruh layer MobileNetV2 dibekukan (*freeze*) sehingga hanya lapisan klasifikasi yang dilatih. Di atas feature extractor MobileNetV2 ditambahkan beberapa lapisan klasifikasi sesuai pada tabel 2:

Tabel 2. lapisan klasifikasi

Layer	Konfigurasi
GlobalAveragePooling2D	Feature Reduction
Dropout	0.5
Dense	256 Neuron, ReLU
Dropout	0.3
Dense Output	Softmax

Lapisan keluaran menggunakan fungsi aktivasi Softmax karena permasalahan yang ditangani merupakan klasifikasi multikelas. Secara matematis, fungsi Softmax dinyatakan sebagai:

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad [14]$$

dengan:

- $(P(y_i))$ = probabilitas kelas ke-i
- (z_i) = nilai logit kelas ke-i
- (K) = jumlah kelas

Pada tahap pelatihan model dilakukan dalam dua tahap, yaitu:

a. Tahap Transfer Learning

Pada tahap pertama seluruh layer MobileNetV2 dibekukan dan hanya lapisan klasifikasi yang diperbarui. Parameter pelatihan sesuai dengan tabel 3:

Tabel 3. Parameter pelatihan

Parameter	Nilai
Optimizer	Adam
Epoch	30
Batch Size	32
Loss Function	Categorical Crossentropy
Learning Rate	Default Adam

Fungsi loss yang digunakan adalah:

$$L = - \sum_{i=1}^K y_i \log(\hat{y}_i) \quad [15]$$

dengan:

- (y_i) = label aktual
- $(\hat{y}_i)$ = probabilitas prediksi

b. Tahap Fine-Tuning

Setelah tahap transfer learning selesai, dilakukan proses fine-tuning untuk meningkatkan kemampuan model dalam mengenali karakteristik spesifik penyakit daun jagung. Pada tahap ini Seluruh model dibuka kembali (*unfreeze*) kemudian Sebanyak 30 layer terakhir MobileNetV2 dilatih ulang dan Layer lainnya tetap dibekukan. Learning rate diturunkan menjadi: 1×10^{-5} menggunakan optimizer Adam agar proses pembelajaran berlangsung lebih stabil.

Strategi Optimasi Pelatihan Untuk meningkatkan stabilitas pelatihan digunakan beberapa callback, yaitu: Early Stopping yaitu menghentikan pelatihan secara otomatis apabila nilai validation loss tidak mengalami perbaikan selama 5 epoch berturut-turut. Kemudian parameter: Patience=5 Reduce Learning Rate on Plateau yaitu menurunkan learning rate ketika validation loss stagnan. Selanjutnya menggunakan Model Checkpoint yaitu menyimpan model terbaik berdasarkan nilai validation accuracy tertinggi selama proses pelatihan. Evaluasi dilakukan menggunakan data pengujian (testing set) yang tidak terlibat dalam proses pelatihan. Metrik evaluasi yang digunakan meliputi:

Accuracy

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad [16]$$

Precision

$$\text{Precision} = \frac{TP}{TP+FP} \quad [17]$$

Recall

$$\text{Recall} = \frac{TP}{TP+FN} \quad [18]$$


F1-Score

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad [19]$$

Keterangan:

- TP = True Positive
- TN = True Negative
- FP = False Positive
- FN = False Negative

Selain itu dilakukan analisis menggunakan Classification Report dan Confusion Matrix untuk mengetahui kemampuan model dalam mengklasifikasikan setiap kelas penyakit daun jagung secara lebih rinci. Tahapan penelitian secara keseluruhan dapat diringkas sebagai pada gambar 2:



Gambar 2. Tahapan penelitian

Penelitian diawali dengan pengumpulan dataset citra daun jagung yang terdiri atas beberapa kelas penyakit dan daun sehat. Selanjutnya dilakukan tahap prapemrosesan citra berupa penyesuaian ukuran gambar dan normalisasi menggunakan fungsi `preprocess_input()` dari MobileNetV2. Untuk meningkatkan keragaman data dan mengurangi risiko overfitting, diterapkan teknik augmentasi data seperti rotasi, pembalikan, zoom, dan perubahan kecerahan. Dataset kemudian dibagi menjadi data pelatihan dan data validasi/pengujian. Model klasifikasi dibangun menggunakan arsitektur MobileNetV2 berbasis transfer learning. Pelatihan dilakukan dalam dua tahap, yaitu feature extraction dengan membekukan seluruh bobot pretrained dan fine-tuning dengan membuka 30 layer terakhir MobileNetV2 untuk meningkatkan kemampuan adaptasi model terhadap karakteristik penyakit daun jagung. Kinerja model dievaluasi menggunakan metrik Accuracy, Precision, Recall, dan F1-Score.

Hasil evaluasi dianalisis lebih lanjut melalui Classification Report dan Confusion Matrix. Model dengan performa terbaik kemudian disimpan dan digunakan sebagai model akhir dalam implementasi sistem deteksi penyakit daun jagung. Metodologi ini dirancang untuk menghasilkan model klasifikasi penyakit daun jagung yang memiliki kemampuan generalisasi tinggi, efisiensi komputasi yang baik, serta akurasi yang optimal dalam mendukung sistem diagnosis penyakit tanaman berbasis kecerdasan buatan.


3 RESULTS AND ANALYSIS

3.1. Result

Tahap awal penelitian dilakukan dengan mempersiapkan dataset citra daun jagung yang terdiri atas tiga kategori, yaitu Hawar Daun (Blight), Karat Daun (Rust), dan Daun Sehat (Healthy). Seluruh citra terlebih dahulu diubah ukurannya menjadi 224×224 piksel sesuai spesifikasi input MobileNetV2. Selain itu, dilakukan normalisasi menggunakan fungsi `preprocess_input()` sehingga distribusi nilai piksel sesuai dengan kebutuhan model pralatih ImageNet. Untuk meningkatkan kemampuan generalisasi model, diterapkan teknik augmentasi data yang meliputi rotasi, pergeseran horizontal dan vertikal, zoom, serta horizontal flipping. Strategi ini bertujuan menghasilkan variasi citra yang lebih beragam sehingga model mampu mengenali karakteristik


penyakit daun jagung pada berbagai kondisi pengambilan gambar. Implementasi augmentasi juga membantu mengurangi risiko overfitting yang umum terjadi pada dataset citra pertanian dengan jumlah sampel terbatas.

Penelitian ini memanfaatkan arsitektur MobileNetV2 sebagai model dasar (*base model*) dengan bobot awal yang berasal dari dataset ImageNet. Pada tahap pertama, seluruh layer konvolusi dibekukan (*freeze layer*) sehingga hanya lapisan klasifikasi yang diperbarui selama proses pelatihan. Penambahan lapisan GlobalAveragePooling2D, Dense 256 neuron, dan Dropout memungkinkan model mempelajari representasi fitur spesifik penyakit daun jagung tanpa kehilangan informasi penting yang telah dipelajari MobileNetV2 dari proses pretraining. Selama proses pelatihan, nilai loss menunjukkan tren penurunan secara bertahap sedangkan nilai accuracy mengalami peningkatan pada data pelatihan maupun validasi. Kondisi tersebut mengindikasikan bahwa proses transfer learning berhasil memanfaatkan fitur visual umum seperti tekstur, warna, pola bercak, dan struktur daun untuk membedakan setiap kategori penyakit sesuai dengan gambar 3.



Gambar 3. arsitektur mobilenetv2 untuk klasifikasi daun jagung

Setelah tahap transfer learning selesai, dilakukan proses fine-tuning dengan membuka kembali sebagian layer MobileNetV2, khususnya 30 layer terakhir. Strategi ini memungkinkan model mempelajari karakteristik yang lebih spesifik terhadap penyakit daun jagung. Penggunaan learning rate yang lebih kecil sebesar: 1×10^{-5} membantu proses pembelajaran berlangsung lebih stabil tanpa merusak bobot penting yang telah diperoleh dari tahap sebelumnya. Hasil fine-tuning menunjukkan peningkatan performa dibandingkan model transfer learning awal. Hal ini menunjukkan bahwa fitur-fitur tingkat tinggi pada MobileNetV2 dapat diadaptasikan secara lebih optimal terhadap karakteristik visual penyakit daun jagung, seperti pola nekrosis, perubahan warna daun, dan penyebaran bercak penyakit.



Gambar 4 Analisis Kurva Accuracy dan Loss

Berdasarkan grafik pelatihan pada gambar 4, selama eksperimen dihasilkan kurva accuracy pada data training dan validation menunjukkan kecenderungan meningkat hingga mencapai kondisi konvergen. Di sisi lain, nilai loss mengalami penurunan secara konsisten sepanjang proses pelatihan. Tidak ditemukannya perbedaan yang terlalu besar antara kurva training dan validation menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Kondisi ini juga menunjukkan bahwa penggunaan augmentasi data serta mekanisme regularisasi berupa Dropout 0,5 dan 0,3 berhasil mengurangi gejala overfitting. Selain itu, penerapan callback Early Stopping dan Reduce Learning Rate on Plateau terbukti membantu proses optimasi sehingga model berhenti pada kondisi performa terbaik tanpa melakukan pelatihan berlebihan.


Metrik	Nilai
Accuracy	0.87 %
Macro Precision	0.87 %
Macro Recall	0.87 %
Macro F1-Score	0.87 %
Weighted Precision	0.87 %
Weighted Recall	0.87 %
Weighted F1-Score	0.87 %
Jumlah Sampel Uji (Support)	61

Tabel 4. Evaluasi Kinerja Model

hasil pada tabel 4 pengujian terhadap 61 data uji, model memperoleh nilai accuracy sebesar 87%, yang menunjukkan bahwa model mampu mengklasifikasikan sebagian besar citra daun jagung dengan benar. Nilai precision, recall, dan F1-score pada rata-rata macro maupun weighted masing-masing sebesar 0,87, mengindikasikan bahwa performa model relatif seimbang pada seluruh kelas dan memiliki kemampuan yang baik dalam mengenali penyakit daun jagung tanpa menunjukkan bias yang signifikan terhadap kelas tertentu. Evaluasi model dilakukan menggunakan data pengujian yang tidak terlibat selama proses pelatihan. Pengukuran performa dilakukan menggunakan metrik Accuracy, Precision, Recall, dan F1-Score. Accuracy digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data uji. Precision menunjukkan kemampuan model dalam menghasilkan prediksi positif yang benar, sedangkan Recall mengukur kemampuan model dalam menemukan seluruh sampel penyakit yang sebenarnya ada. Sementara itu, F1-Score digunakan sebagai indikator keseimbangan antara Precision dan Recall [20].

Tingginya nilai Precision menunjukkan bahwa sebagian besar prediksi penyakit yang dihasilkan model memang benar merupakan penyakit yang sesuai. Nilai Recall yang tinggi menunjukkan kemampuan model mendeteksi penyakit secara efektif sehingga meminimalkan kemungkinan penyakit tidak terdeteksi (*false negative*). Kombinasi kedua metrik tersebut menghasilkan nilai F1-Score yang baik sehingga model dapat digunakan sebagai sistem pendukung diagnosis awal penyakit daun jagung.

Confusion Matrix digunakan untuk mengevaluasi performa model pada masing-masing kelas penyakit sesuai dengan pernyataan [21]. Secara umum, sebagian besar sampel daun sehat berhasil diklasifikasikan dengan benar karena memiliki karakteristik visual yang cukup berbeda dibandingkan daun yang terinfeksi penyakit. Pada kelas Hawar Daun dan Karat Daun, terdapat sejumlah kecil kesalahan klasifikasi yang disebabkan oleh kemiripan gejala visual berupa perubahan warna daun dan munculnya bercak pada permukaan daun. Meskipun demikian, jumlah prediksi benar (True Positive) masih mendominasi dibandingkan prediksi salah (False Positive maupun False Negative), yang menunjukkan bahwa model memiliki kemampuan diskriminatif yang baik dalam membedakan ketiga kelas sesuai pada gambar 4.



Gambar 4 Analisis Confusion Matrix

3.2. Analysis

Hasil penelitian menunjukkan bahwa penerapan transfer learning menggunakan MobileNetV2 mampu menghasilkan model klasifikasi penyakit daun jagung yang efektif dan efisien. Keunggulan utama MobileNetV2 terletak pada penggunaan mekanisme *depthwise separable convolution* yang memungkinkan jumlah parameter lebih sedikit dibandingkan CNN konvensional, sehingga proses pelatihan menjadi lebih cepat tanpa mengorbankan akurasi secara signifikan sejalan dengan penelitian [22].

Keberhasilan model dalam mengenali penyakit daun jagung juga dipengaruhi oleh penerapan augmentasi data yang mampu memperkaya variasi sampel pelatihan. Teknik ini memungkinkan model menjadi lebih robust terhadap perubahan orientasi daun, pencahayaan, dan variasi kondisi lapangan [23]. Selain itu, proses fine-tuning memberikan kontribusi penting terhadap peningkatan performa model. Dengan membuka sebagian layer MobileNetV2, model mampu mempelajari fitur-fitur spesifik yang berkaitan dengan karakteristik penyakit tanaman yang tidak tersedia pada dataset ImageNet. Temuan ini menunjukkan bahwa kombinasi transfer learning dan fine-tuning merupakan pendekatan yang efektif untuk klasifikasi penyakit tanaman berbasis citra sesuai dengan penelitian [24].

Secara keseluruhan, model yang dikembangkan memiliki potensi untuk diimplementasikan pada sistem diagnosis penyakit tanaman berbasis perangkat bergerak (*mobile-based plant disease detection system*) karena MobileNetV2 memiliki ukuran model yang relatif ringan dan kebutuhan komputasi yang rendah. Dengan demikian, model dapat mendukung proses monitoring kesehatan tanaman secara cepat, akurat, dan efisien pada lingkungan pertanian modern.

4 CONCLUSION

Penelitian ini berhasil mengembangkan model klasifikasi penyakit daun jagung berbasis Deep Learning menggunakan arsitektur MobileNetV2 dengan pendekatan transfer learning dan fine-tuning. Model dibangun untuk mengidentifikasi tiga kategori kondisi daun jagung, yaitu Hawar Daun (*Blight*), Karat Daun (*Rust*), dan Daun Sehat (*Healthy*) berdasarkan citra digital yang diperoleh dari dataset publik Kaggle. Tahap prapemrosesan data dilakukan melalui normalisasi citra dan augmentasi data yang meliputi rotasi, translasi, zoom, dan horizontal flipping. Teknik augmentasi terbukti mampu meningkatkan keragaman data pelatihan sehingga model memiliki kemampuan generalisasi yang lebih baik terhadap variasi kondisi citra di lapangan. Selain

itu, penggunaan MobileNetV2 sebagai model dasar memungkinkan proses ekstraksi fitur dilakukan secara efisien dengan jumlah parameter yang relatif kecil dibandingkan arsitektur CNN konvensional.

Hasil pelatihan menunjukkan bahwa pendekatan transfer learning mampu mempercepat proses konvergensi model karena memanfaatkan bobot awal hasil pelatihan pada dataset ImageNet. Selanjutnya, proses fine-tuning pada layer-layer akhir MobileNetV2 memberikan peningkatan kemampuan model dalam mengenali karakteristik spesifik penyakit daun jagung, seperti perubahan warna, bercak nekrotik, dan pola kerusakan jaringan daun. Berdasarkan hasil evaluasi menggunakan metrik Accuracy, Precision, Recall, dan F1-Score, model menunjukkan performa yang baik dalam membedakan daun sehat dan daun yang terinfeksi penyakit. Analisis Confusion Matrix juga menunjukkan bahwa sebagian besar sampel berhasil diklasifikasikan dengan benar, meskipun masih ditemukan sejumlah kecil kesalahan klasifikasi pada kelas yang memiliki karakteristik visual yang mirip. Secara keseluruhan, penelitian ini membuktikan bahwa kombinasi teknik augmentasi data, transfer learning, dan fine-tuning pada MobileNetV2 merupakan pendekatan yang efektif untuk mendukung deteksi dini penyakit daun jagung. Model yang dihasilkan memiliki potensi untuk diimplementasikan pada sistem pertanian cerdas (*smart agriculture*) maupun aplikasi berbasis perangkat bergerak sebagai alat bantu monitoring kesehatan tanaman secara cepat, akurat, dan efisien.

5 ACKNOWLEDGEMENTS

Untuk penelitian selanjutnya disarankan menggunakan: a) Jumlah dataset dapat ditambah dengan citra dari berbagai kondisi lingkungan, pencahayaan, umur tanaman, dan jenis kamera agar model lebih mampu mengenali penyakit pada kondisi nyata di lapangan. b) Penelitian selanjutnya dapat membandingkan MobileNetV2 dengan model lain seperti EfficientNet, ConvNeXt, Vision Transformer, atau YOLOv8 untuk mengetahui model yang paling efektif dan efisien. c) Optimasi hiperparameter, seperti learning rate, batch size, dan konfigurasi fine-tuning, dapat dilakukan menggunakan metode otomatis agar performa model menjadi lebih baik. d) Model dapat dikembangkan dengan mengintegrasikan sistem deteksi objek berbasis YOLO sehingga tidak hanya mengklasifikasikan penyakit, tetapi juga menunjukkan lokasi penyakit pada daun. e) Model dapat diimplementasikan pada aplikasi Android, web, atau perangkat IoT untuk membantu petani melakukan identifikasi penyakit secara real-time. Selain itu, model dapat dikonversi ke format TensorFlow Lite agar lebih ringan dan cepat dijalankan pada perangkat dengan sumber daya terbatas.

Dengan pengembangan lebih lanjut pada aspek dataset, arsitektur model, optimasi parameter, dan implementasi sistem, diharapkan penelitian ini dapat memberikan kontribusi yang lebih besar terhadap pengembangan teknologi kecerdasan buatan di bidang pertanian presisi (*precision agriculture*) dan sistem deteksi penyakit tanaman secara otomatis.

REFERENCES

- [1] Badan Pusat Statistik, "Luas Panen dan Produksi Jagung di Indonesia 2023." BPS RI, 2024. [Online]. Available: <https://www.bps.go.id>
- [2] R. Astari and N. D. Lestari, "Pengaruh Serangan Hama dan Penyakit terhadap Produktivitas Jagung di Indonesia," *J. Pertan. Presisi*, vol. 8, no. 1, pp. 45–58, 2024.
- [3] R. Ruimassa and others, "Intensitas Serangan Penyakit Karat Daun Jagung pada Berbagai Varietas," *J. Agroplasma*, vol. 10, no. 1, pp. 12–21, 2023.
- [4] Badan Pusat Statistik, "Luas Panen dan Produksi Jagung di Indonesia 2024 (Angka Tetap)." BPS RI, 2025. [Online]. Available: <https://www.bps.go.id>
- [5] D. Dai, P. Xia, Z. Zhu, and H. Che, "MTDL-EPDCLD: A Multi-Task Deep-Learning-Based System for Enhanced Precision Detection and Diagnosis of Corn Leaf Diseases," *Plants*, vol. 12, no. 13, p. 2433, 2023, doi: 10.3390/plants12132433.
- [6] M. Alkanan and Y. Gulzar, "Enhanced Corn Seed Disease Classification: Leveraging MobileNetV2 with Feature Augmentation and Transfer Learning," *Front. Appl. Math. Stat.*, vol. 9, p. 1320177, 2024, doi: 10.3389/fams.2023.1320177.

- [7] J. Liu, C. He, Y. Jiang, M. Wang, Z. Ye, and M. He, "A High-Precision Identification Method for Maize Leaf Diseases and Pests Based on LFMNet under Complex Backgrounds," *Plants*, vol. 13, no. 13, p. 1827, 2024, doi: 10.3390/plants13131827.
- [8] J. Nakatumba-Nabende and S. Murindanyi, "Deep Learning Models for Enhanced In-Field Maize Leaf Disease Diagnosis," *Mach. Learn. Appl.*, vol. 20, p. 100673, 2025, doi: 10.1016/j.mlwa.2025.100673.
- [9] K. Gopalan, S. Srinivasan, P. Agarwal, M. Singh, S. K. Mathivanan, and U. Moorthy, "Corn Leaf Disease Diagnosis: Enhancing Accuracy with ResNet152 and Grad-CAM for Explainable AI," *BMC Plant Biol.*, vol. 25, p. 412, 2025, doi: 10.1186/s12870-025-06386-0.
- [10] M. Ali, "Classification of Maize Leaf Diseases with Deep Learning: Performance Evaluation of the Proposed Model and Use of Explicable Artificial Intelligence," *Pattern Recognit.*, vol. 162, p. 111371, 2025, doi: 10.1016/j.patcog.2025.111371.
- [11] Y. Özüpak, "Hybrid Deep Learning Model for Maize Leaf Disease Classification with Explainable AI," *N. Z. J. Crop Hortic. Sci.*, vol. 53, no. 5, pp. 2942–2964, 2025, doi: 10.1080/01140671.2025.2519570.
- [12] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.
- [13] I. P. Agus, K. Hidjah, N. Sulistianingsih, G. Hendro, and S. Syahrir, "Implementasi Arsitektur Deep Convolutional Neural Network (CNN) dengan Transfer Learning untuk Klasifikasi Penyakit Kulit," *J. Teknol. Inf. Dan Multimed.*, vol. 7, no. 3, pp. 461–477, 2025.
- [14] S. S. La Ode Ansyarullah, "Klasifikasi Cats dan Dogs dengan Metode CNN dalam Fungsi Aktivasi relu, sigmoid, softmax, softplus, softsign, dan selu".
- [15] A. Alfakhri and S. Suseno, "Evaluasi Optimal Pemilihan Pemasok Limbah Botol PET untuk Mitra Bank Sampah Menggunakan Metode AHP dan Taguchi Loss Function:(Studi Kasus: PT Anugrah Alam Manunggal)," *J. Teknol. Dan Manaj. Ind. Terap.*, vol. 3, no. 3, pp. 334–347, 2024.
- [16] A. P. Ayudhitama and U. Pujiyanto, "Analisa 4 Algoritma Dalam klasifikasi liver menggunakan RAPIDMINER," *J. Inform. Polinema*, vol. 6, no. 2, pp. 1–9, 2020.
- [17] M. Azhari, Z. Situmorang, and R. Rosnelly, "Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes," *J. Media Inform. Budidarma*, vol. 5, no. 2, p. 640, 2021.
- [18] A. M. Argina, "Penerapan metode klasifikasi k-nearest neighbor pada dataset penderita penyakit diabetes," *Indones. J. Data Sci.*, vol. 1, no. 2, pp. 29–33, 2020.
- [19] S. Suprihanto, I. Awaludin, M. Fadhil, and M. A. Z. Zulfikor, "Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta," *J Inf.*, vol. 9, no. 2, pp. 116–122, 2022.
- [20] T. H. Pinem and Z. P. Putra, "Evaluasi Kinerja Algoritma Klasifikasi Deep Learning dalam Prediksi Diabetes," *J. Ilm. FIFO*, vol. 17, no. 1, pp. 17–28, 2025.
- [21] R. Ridwan, H. H. Handayani, S. A. P. Lestari, and Y. Cahyana, "Evaluasi Kinerja Algoritma Random Forest Dan Gradient Boosting Untuk Klasifikasi Penyakit Jantung," *J. Komtika Komputasi Dan Inform.*, vol. 9, no. 1, pp. 112–124, 2025.
- [22] K. A. Tamayasa and L. J. E. Dewi, "ANALISIS PERBANDINGAN MODEL ARSITEKTUR MOBILENETV2 DAN EFFICIENTNETB3 DALAM KLASIFIKASI PENYAKIT DAUN JAGUNG," *J. Inform. Dan Tek. Elektro Terap.*, vol. 14, no. 1, 2026.
- [23] P. Novantara, R. L. Firmansyah, and M. Arismawati, "Deteksi Hama Penyakit Daun Padi Dengan Menggunakan Teknik Optimasi Deep Learning Convolutional Neural Network," *Bit-Tech*, vol. 7, no. 3, pp. 975–983, 2025.
- [24] S. Agustiani, R. Aryanti, S. K. Wildah, Y. T. Arifin, S. Marlina, and T. Misriati, "Optimisasi Model Deep Learning untuk Deteksi Penyakit Daun Tebu dengan Fine-Tuning MobileNetV2," *J. Inform. Manag. Inf. Technol.*, vol. 4, no. 4, pp. 150–157, 2024.