

Klasifikasi Penyakit Daun Jagung Menggunakan Transfer Learning MobileNetV2 dengan Fine-Tuning

Moh. Sa'id Ramdhoni¹ Hairani²
Universitas Bumigora, Mataram, Indonesia

Article Info

Article history:

Received mm dd, yyyy

Revised mm dd, yyyy

Accepted mm dd, yyyy

Keywords:

Fine-Tuning

Klasifikasi Citra

MobileNetV2

Penyakit Daun Jagung

Transfer Learning

ABSTRACT

Penyakit pada daun jagung, seperti *Blight*, *Common Rust*, dan *Gray Leaf Spot*, dapat menurunkan kualitas dan hasil panen. Identifikasi penyakit yang masih dilakukan secara manual memerlukan waktu dan berpotensi menghasilkan kesalahan, terutama ketika gejala antarpengakit memiliki kemiripan visual. Penelitian ini bertujuan untuk mengklasifikasikan empat kondisi daun jagung, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*, menggunakan metode *Transfer Learning* dengan arsitektur MobileNetV2 yang dipadukan dengan teknik *fine-tuning*. Dataset yang digunakan merupakan dataset publik yang terdiri atas 4.188 citra daun jagung dan dibagi menjadi data pelatihan sebesar 80% serta data validasi sebesar 20%. Tahap *feature extraction* dilakukan dengan membekukan lapisan konvolusi, kemudian dilanjutkan dengan *fine-tuning* pada sebagian lapisan konvolusi menggunakan *learning rate* yang lebih rendah. Hasil evaluasi menunjukkan bahwa model memperoleh akurasi sebesar 96%, dengan nilai *recall* sebesar 1,00 pada kelas *Healthy* dan nilai *F1-score* sebesar 0,99 pada kelas *Common Rust*. Kesalahan klasifikasi masih ditemukan antara kelas *Blight* dan *Gray Leaf Spot* karena kedua kelas memiliki karakteristik visual yang serupa. Hasil penelitian menunjukkan bahwa MobileNetV2 dengan teknik *fine-tuning* mampu mengklasifikasikan citra penyakit daun jagung dengan baik pada dataset yang digunakan.

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



Corresponding Author:

Moh. Sa'id Ramdhoni,

Universitas Bumigora, Mataram, Indonesia.

Email: dhoni.nuck@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.v 0i0.000](https://doi.org/10.30812/vertex.v2i2.000).

1 INTRODUCTION

Jagung merupakan salah satu komoditas pangan yang berperan dalam mendukung ketahanan pangan, baik pada tingkat global maupun nasional [1]. Peningkatan jumlah penduduk menyebabkan kebutuhan terhadap hasil produksi pertanian terus bertambah sehingga produktivitas dan kualitas panen perlu dipertahankan. Dalam proses budidayanya, tanaman jagung menghadapi berbagai kendala, salah satunya adalah serangan organisme pengganggu tanaman yang dapat menyebabkan berbagai jenis penyakit [2]. Penyakit pada tanaman jagung berpotensi menurunkan hasil panen, baik dari sisi kuantitas maupun kualitas

produk yang dihasilkan [3]. Oleh karena itu, pemantauan kondisi kesehatan tanaman perlu dilakukan secara berkelanjutan sebagai upaya untuk menjaga produktivitas tanaman dan mendukung ketersediaan pangan [4].

Indikasi awal penyakit pada tanaman jagung umumnya ditandai dengan perubahan pola dan warna pada permukaan daun. Beberapa penyakit, seperti hawar daun, karat daun, dan bercak daun abu-abu, memiliki karakteristik visual yang cenderung serupa pada fase awal infeksi sehingga sulit dibedakan melalui pengamatan secara langsung [5]. Selama ini, identifikasi penyakit masih banyak dilakukan oleh petani melalui pengamatan visual di lahan pertanian. Metode tersebut memerlukan waktu serta bergantung pada kemampuan dan pengalaman masing-masing individu, sehingga berpotensi menimbulkan kesalahan dalam proses identifikasi [6]. Kesalahan dalam menentukan jenis penyakit dapat menyebabkan pemberian penanganan yang tidak sesuai, sehingga kondisi tanaman berpotensi mengalami kerusakan lebih lanjut. Oleh karena itu, diperlukan suatu sistem deteksi otomatis yang mampu membantu proses identifikasi penyakit pada tanaman jagung secara lebih cepat dan konsisten [7].

Berbagai penelitian telah dilakukan untuk mengembangkan sistem deteksi penyakit daun jagung menggunakan berbagai pendekatan klasifikasi. Suhendra dkk. (2022) menerapkan metode Support Vector Machine (SVM) dengan memanfaatkan ekstraksi fitur warna dan tekstur secara manual, serta memperoleh akurasi sebesar 99,5% [6]. Pada pendekatan pembelajaran mendalam, Azizah (2023) menggunakan arsitektur AlexNet untuk mengklasifikasikan empat jenis kondisi daun jagung dengan akurasi pengujian sebesar 90% [7]. Selanjutnya, Akhyari dkk. (2021) mengimplementasikan arsitektur VGG-16 dan memperoleh akurasi sebesar 98%, sedangkan Putra dkk. (2022) menerapkan arsitektur ResNet-50 dengan optimizer Adam dan menghasilkan akurasi sebesar 98,4% [5],[3]. Hasil-hasil penelitian tersebut menunjukkan bahwa metode pembelajaran mesin maupun pembelajaran mendalam memiliki potensi dalam mendukung proses identifikasi penyakit daun jagung.

Meskipun demikian, masih terdapat beberapa keterbatasan yang dapat menjadi dasar pengembangan penelitian lebih lanjut. Arsitektur VGG-16 dan ResNet-50 memerlukan sumber daya komputasi yang relatif besar sehingga kurang sesuai untuk diterapkan pada perangkat dengan spesifikasi terbatas [8]. Selain itu, penelitian yang menggunakan metode ResNet-50 dan SVM hanya difokuskan pada klasifikasi biner, yaitu membedakan daun sehat dan daun yang terinfeksi, sehingga belum mampu mengidentifikasi jenis penyakit secara spesifik [3],[6]. Di sisi lain, penerapan AlexNet pada klasifikasi multikelas masih menunjukkan keterbatasan dalam membedakan karakteristik visual antarpenyakit yang memiliki kemiripan, sehingga akurasi yang diperoleh lebih rendah dibandingkan pendekatan lainnya [7]. Berdasarkan kondisi tersebut, masih terdapat peluang penelitian untuk mengembangkan model klasifikasi multikelas yang mampu mempertahankan kinerja klasifikasi dengan kebutuhan komputasi yang lebih efisien.

Berdasarkan celah penelitian tersebut, penelitian ini mengusulkan penerapan arsitektur *MobileNetV2* yang dioptimalkan menggunakan teknik *fine-tuning* untuk klasifikasi penyakit daun jagung. *MobileNetV2* merupakan arsitektur jaringan saraf tiruan yang dirancang agar memiliki kebutuhan komputasi yang lebih rendah dibandingkan beberapa arsitektur pembelajaran mendalam lainnya, sehingga sesuai untuk diterapkan pada perangkat dengan sumber daya terbatas [9]. Pada penelitian ini, proses *fine-tuning* dilakukan dengan melatih kembali sebagian lapisan konvolusi pada tingkat akhir menggunakan laju pembelajaran yang rendah agar model dapat menyesuaikan representasi fitur dengan karakteristik empat kelas penyakit daun jagung tanpa menghilangkan informasi yang telah dipelajari pada tahap *pre-training* [1]. Selain itu, penelitian ini menggunakan data pelatihan tanpa penambahan data sintesis (*data augmentation*), sehingga evaluasi difokuskan pada kemampuan *MobileNetV2* dengan teknik *fine-tuning* dalam mempelajari karakteristik data asli. Melalui pendekatan tersebut, penelitian ini diharapkan dapat menghasilkan model klasifikasi multikelas yang memiliki kinerja klasifikasi yang baik dengan kebutuhan komputasi yang lebih efisien dibandingkan beberapa pendekatan yang telah digunakan pada penelitian sebelumnya.

Penelitian ini bertujuan untuk mengklasifikasikan empat kondisi daun jagung, yaitu bercak daun, hawar daun, karat daun, dan daun sehat, menggunakan metode *Transfer Learning MobileNetV2* dengan teknik *fine-tuning*. Evaluasi dilakukan untuk


mengukur kinerja model berdasarkan metrik evaluasi yang digunakan serta menganalisis kemampuan arsitektur *MobileNetV2* dalam mengklasifikasikan penyakit daun jagung pada skenario multikelas. Hasil penelitian ini diharapkan dapat menjadi salah satu referensi dalam pengembangan sistem deteksi penyakit daun jagung secara otomatis yang dapat membantu proses identifikasi penyakit secara lebih cepat dan konsisten.

2 RESEARCH METHOD

Bagian ini menjelaskan tahapan penelitian yang dilakukan, mulai dari pengumpulan data, prapemrosesan, pelatihan model, hingga evaluasi hasil klasifikasi. Penelitian menggunakan metode eksperimen dengan menerapkan *transfer learning* dan *fine-tuning* pada arsitektur *MobileNetV2* untuk mengklasifikasikan kondisi daun jagung. Seluruh tahapan penelitian dilaksanakan menggunakan bahasa pemrograman Python dengan pustaka PyTorch serta didukung oleh perangkat keras GPU untuk mempercepat proses pelatihan dan pengujian model.

2.1. Tahapan Penelitian

Penelitian ini dilaksanakan melalui lima tahapan utama, yaitu pengumpulan dataset, *preprocessing* data, pembagian data, pemodelan, dan evaluasi. Setiap tahapan disusun secara berurutan untuk membangun model klasifikasi penyakit daun jagung menggunakan metode *Transfer Learning* *MobileNetV2* dengan teknik *fine-tuning*. Proses penelitian diawali dengan pengumpulan dataset citra daun jagung, kemudian dilanjutkan dengan tahap *preprocessing* agar data sesuai dengan spesifikasi masukan model. Selanjutnya, dataset dibagi menjadi data pelatihan dan data validasi sebelum digunakan pada proses pelatihan model. Tahap terakhir adalah evaluasi untuk mengukur kinerja model berdasarkan hasil klasifikasi. Alur tahapan penelitian ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Berdasarkan Gambar 1, penelitian diawali dengan penggunaan dataset citra daun jagung yang terdiri atas empat kelas, yaitu *Blight* (Hawar Daun), *Common Rust* (Karat Daun), *Gray Leaf Spot* (Bercak Daun Abu-abu), dan *Healthy* (Sehat). Selanjutnya, dilakukan tahap *preprocessing* untuk menyesuaikan data dengan spesifikasi masukan *MobileNetV2*. Tahap ini meliputi perubahan ukuran citra menjadi 224×224 piksel, konversi citra ke dalam format tensor, serta normalisasi nilai piksel menggunakan parameter *mean* dan *standard deviation* ImageNet. Penelitian ini tidak menerapkan *data augmentation*, sehingga proses pelatihan menggunakan data asli yang tersedia.

Setelah melalui tahap *preprocessing*, dataset dibagi menjadi data pelatihan (*training set*) sebesar 80% dan data validasi (*validation set*) sebesar 20%. Data pelatihan digunakan untuk melatih model, sedangkan data validasi digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan data yang tidak digunakan selama proses pelatihan. Tahap pemodelan menerapkan metode *Transfer Learning* pada arsitektur *MobileNetV2* yang dilaksanakan dalam dua tahap, yaitu ekstraksi fitur dengan membekukan (*freeze*) parameter pada lapisan konvolusi dasar dan hanya melatih lapisan klasifikasi, kemudian dilanjutkan dengan *fine-tuning* melalui pelatihan kembali sebagian lapisan konvolusi pada bagian akhir model menggunakan *learning rate* yang lebih rendah agar model dapat menyesuaikan representasi fitur dengan karakteristik dataset penelitian. Selanjutnya, kinerja model dievaluasi menggunakan data validasi berdasarkan metrik akurasi, presisi, *recall*, dan *F1-score*. Selain itu, hasil klasifikasi divisualisasikan menggunakan *confusion matrix* untuk menunjukkan distribusi prediksi pada setiap kelas serta mengidentifikasi kesalahan klasifikasi yang terjadi.

2.2. Pengumpulan Data

Penelitian ini menggunakan dataset sekunder berupa Corn or Maize Leaf Disease Dataset yang tersedia pada repositori Kaggle dan dapat diakses melalui tautan <https://www.kaggle.com/smaranjitghose/corn-or-maize-leaf-disease-dataset>. Dataset tersebut dipilih karena telah banyak digunakan pada penelitian klasifikasi penyakit daun jagung sehingga dapat mendukung perbandingan hasil penelitian dengan studi terdahulu. Dataset terdiri atas citra daun jagung berformat RGB yang dikelompokkan ke dalam empat kelas, yaitu *Blight* (Hawar Daun), *Common Rust* (Karat Daun), *Gray Leaf Spot* (Bercak Daun Abu-abu), dan *Healthy* (Sehat). Rincian nama kelas, contoh citra, dan jumlah data pada setiap kelas disajikan pada Tabel 1.

Tabel 1. Dataset Penyakit Kulit

No	Gambar	Nama Penyakit	Jumlah Citra
1		<i>Blight</i> (Hawar Daun)	1.146
2		<i>Common Rust</i> (Karat Daun)	1.306
3		<i>Gray Leaf Spot</i> (Bercak Daun Abu-abu)	574
4		<i>Healthy</i> (Daun Sehat)	1.162

Berdasarkan distribusi data pada Tabel 1, penelitian ini menggunakan sebanyak 4.188 citra daun jagung yang terdiri atas empat kelas. Kelas *Common Rust* memiliki jumlah citra terbanyak, yaitu 1.306 citra, diikuti oleh kelas *Healthy* sebanyak 1.162 citra dan kelas *Blight* sebanyak 1.146 citra. Sementara itu, kelas *Gray Leaf Spot* memiliki jumlah citra paling sedikit, yaitu 574 citra. Distribusi tersebut menunjukkan adanya perbedaan jumlah sampel pada setiap kelas, dengan kelas *Gray Leaf Spot* sebagai kelas yang memiliki proporsi data paling rendah. Kondisi ini perlu diperhatikan karena dapat memengaruhi proses pelatihan model dalam membedakan karakteristik setiap kelas. Oleh karena itu, penelitian ini menerapkan metode *Transfer Learning* menggunakan arsitektur MobileNetV2 dengan teknik *fine-tuning* untuk mengevaluasi kemampuan model dalam mengklasifikasikan empat kelas penyakit daun jagung berdasarkan distribusi data yang tersedia, tanpa menerapkan *data augmentation* maupun teknik penyeimbangan data.

2.3. Preprocessing Data

Tahap *preprocessing* bertujuan untuk menyesuaikan format citra agar sesuai dengan masukan arsitektur MobileNetV2. Pada penelitian ini, proses *preprocessing* dilakukan tanpa menerapkan *data augmentation*, sehingga seluruh proses pelatihan menggunakan data asli yang tersedia. Tahapan yang dilakukan meliputi perubahan ukuran citra (*resizing*) menjadi 224×224 piksel, konversi citra ke dalam format tensor menggunakan pustaka PyTorch, serta normalisasi nilai piksel pada setiap kanal RGB menggunakan parameter *mean* [0.485, 0.456, 0.406] dan *standard deviation* [0.229, 0.224, 0.225]. Parameter normalisasi tersebut mengikuti konfigurasi dataset ImageNet yang digunakan pada proses *pre-training* MobileNetV2.

2.4. Pembagian Data

Setelah melalui tahap *preprocessing*, dataset dibagi menjadi dua bagian, yaitu data pelatihan (*training set*) dan data validasi (*validation set*) dengan rasio 80:20. Dari total 4.188 citra, sebanyak 3.351 citra digunakan sebagai data pelatihan, sedangkan 837 citra digunakan sebagai data validasi. Data pelatihan digunakan untuk melatih model MobileNetV2, sementara data validasi digunakan untuk mengevaluasi kinerja model selama proses pelatihan.

Pembagian data dilakukan secara acak menggunakan parameter *random seed* yang tetap untuk memastikan hasil pembagian data dapat direproduksi pada setiap percobaan. Data validasi tidak digunakan dalam proses pembaruan parameter model, tetapi digunakan untuk memantau kinerja model pada setiap *epoch* serta menentukan model dengan kinerja terbaik berdasarkan nilai metrik evaluasi.

2.5. Pemodelan

Tahap pemodelan menggunakan metode *Transfer Learning* dengan arsitektur MobileNetV2 yang telah memiliki bobot awal (*pre-trained weights*) dari dataset ImageNet. Model ini dipilih karena memiliki jumlah parameter yang lebih sedikit dibandingkan beberapa arsitektur CNN lainnya sehingga lebih efisien dalam kebutuhan komputasi. Arsitektur MobileNetV2 kemudian dimodifikasi dengan mengganti lapisan klasifikasi (*classifier*) agar menghasilkan keluaran sebanyak empat kelas sesuai dengan kategori penyakit daun jagung pada penelitian ini.

Proses pelatihan dilakukan dalam dua tahap, yaitu *feature extraction* dan *fine-tuning*. Pada tahap *feature extraction*, seluruh lapisan konvolusi dibekukan (*freeze*) sehingga hanya lapisan klasifikasi yang diperbarui selama proses pelatihan. Selanjutnya, pada tahap *fine-tuning*, sebagian lapisan konvolusi pada bagian akhir model dibuka kembali (*unfreeze*) untuk dilatih bersama lapisan klasifikasi menggunakan *learning rate* yang lebih rendah. Selama proses pelatihan, optimasi parameter dilakukan menggunakan algoritma Adam dengan fungsi kerugian (*loss function*) *Cross-Entropy Loss*. Konfigurasi pelatihan yang digunakan pada penelitian ini disajikan pada Tabel 2.

Tabel 2. Konfigurasi Pelatihan Model	
Parameter	Nilai
Bobot Awal (<i>Pre-trained Weights</i>)	ImageNet
Batch Size	32
Optimizer	Adam
Loss Function	Cross-Entropy Loss
<i>Learning Rate (Feature Extraction)</i>	0,001
<i>Learning Rate (Fine-Tuning)</i>	0,0001
Epoch <i>Feature Extraction</i>	10
Epoch <i>Fine-Tuning</i>	10

Berdasarkan Tabel 2, proses pelatihan dilakukan dalam dua tahap dengan konfigurasi *learning rate* yang berbeda. Pada tahap *feature extraction*, hanya lapisan klasifikasi yang dilatih, sedangkan pada tahap *fine-tuning* sebagian lapisan konvolusi pada bagian akhir model dilatih kembali menggunakan *learning rate* yang lebih rendah. Seluruh proses implementasi dilakukan menggunakan framework PyTorch.

2.6. Evaluasi Model

Tahap evaluasi dilakukan untuk mengukur kinerja model dalam mengklasifikasikan citra daun jagung pada data validasi. Evaluasi menggunakan beberapa metrik klasifikasi, yaitu *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, dan *classification report*. Metrik-metrik tersebut digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan setiap kelas penyakit daun jagung. [10].

Accuracy digunakan untuk mengukur tingkat ketepatan model dalam mengklasifikasikan seluruh data validasi. [11].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Precision digunakan untuk mengukur ketepatan prediksi model terhadap suatu kelas tertentu [11].

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Recall digunakan untuk mengukur kemampuan model dalam mengenali seluruh data positif yang sebenarnya [11].

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

F1-score merupakan rata-rata harmonik antara *precision* dan *recall* yang digunakan untuk melihat keseimbangan performa model [11].

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Confusion matrix digunakan untuk membandingkan hasil prediksi model dengan label aktual dalam bentuk matriks sehingga dapat menunjukkan jumlah prediksi yang benar maupun yang salah pada setiap kelas penyakit daun jagung [12]. Melalui *confusion matrix*, pola kesalahan klasifikasi dapat dianalisis untuk mengetahui kelas yang masih sulit dibedakan oleh model.

Selain itu, penelitian ini menggunakan *classification report* yang menyajikan nilai *precision*, *recall*, *F1-score*, dan *support* untuk setiap kelas. Hasil evaluasi digunakan untuk menganalisis kinerja model MobileNetV2 dengan teknik *fine-tuning* dalam mengklasifikasikan empat kelas penyakit daun jagung. Sebagai pelengkap, kurva *training loss*, *validation loss*, *training accuracy*, dan *validation accuracy* dianalisis untuk melihat perkembangan proses pelatihan serta kinerja model pada data validasi.

3 RESULTS AND ANALYSIS

Bagian ini menyajikan hasil pengujian dan evaluasi kinerja dari arsitektur MobileNetV2 yang telah dilatih untuk mengklasifikasikan empat jenis kondisi daun jagung. Analisis difokuskan pada pergerakan metrik evaluasi selama fase pelatihan, dampak penerapan teknik *fine-tuning* terhadap peningkatan akurasi model, serta pengukuran performa akhir yang divisualisasikan melalui *confusion matrix* dan laporan klasifikasi.

3.1. Hasil Pelatihan Model


Proses pelatihan model MobileNetV2 dilakukan dalam dua tahap, yaitu *feature extraction* dan *fine-tuning*. Pada tahap *feature extraction*, seluruh lapisan konvolusi dibekukan (*freeze*) sehingga hanya lapisan klasifikasi yang diperbarui selama proses pelatihan. Setelah tahap tersebut selesai, pelatihan dilanjutkan menggunakan teknik *fine-tuning* dengan membuka kembali sebagian lapisan konvolusi pada bagian akhir model untuk meningkatkan kemampuan model dalam mempelajari karakteristik penyakit daun jagung. Ringkasan hasil pelatihan pada kedua tahap disajikan pada Tabel 3.

Tabel 3. Hasil Pelatihan Model MobileNetV2

Tahap Pelatihan	Epoch Terbaik	Akurasi Pelatihan (%)	Akurasi Validasi (%)	Training Loss	Validation Loss
Feature Extraction	5	91,05	91,88	0,2383	0,2249
Fine-Tuning	7	99,64	95,58	0,0165	0,1578


Berdasarkan Tabel 3, tahap *fine-tuning* menghasilkan peningkatan kinerja dibandingkan tahap *feature extraction*. Akurasi validasi meningkat dari 91,88% menjadi 95,58%, sedangkan nilai *validation loss* menurun dari 0,2249 menjadi 0,1578. Selain itu, akurasi pelatihan juga meningkat dari 91,05% menjadi 99,64%, yang menunjukkan bahwa model mampu mempelajari representasi fitur yang lebih baik setelah sebagian lapisan konvolusi dilatih kembali.

Perkembangan nilai *training accuracy*, *validation accuracy*, *training loss*, dan *validation loss* selama tahap *feature extraction* ditunjukkan pada Gambar 2. Pada tahap ini, akurasi validasi mengalami peningkatan dari 90,20% pada *epoch* pertama menjadi 91,88% pada *epoch* kelima. Setelah itu, perubahan akurasi validasi relatif kecil hingga akhir pelatihan, dengan nilai berada pada rentang 91,40%–91,88%. Di sisi lain, nilai *training loss* dan *validation loss* menunjukkan kecenderungan menurun selama proses pelatihan.



Gambar 2. Grafik Akurasi dan Loss pada Tahap Feature Extraction


Selanjutnya, proses pelatihan dilanjutkan menggunakan teknik *fine-tuning*. Hasil pelatihan pada Gambar 3 menunjukkan bahwa akurasi validasi meningkat sejak *epoch* pertama dan mencapai nilai tertinggi sebesar 95,58% pada *epoch* ketujuh. Pada saat yang sama, *training loss* menurun hingga 0,0165, sedangkan *validation loss* mencapai nilai terendah pada kisaran 0,1578. Setelah *epoch* ketujuh, nilai *training loss* masih mengalami penurunan, namun *validation loss* mulai meningkat hingga 0,1886 pada *epoch* ke-10. Kondisi tersebut mengindikasikan adanya kecenderungan *overfitting* pada beberapa *epoch* terakhir. Oleh karena itu, model pada *epoch* ketujuh, yang memiliki akurasi validasi tertinggi, dipilih sebagai model akhir untuk tahap evaluasi.



Gambar 3. Grafik Akurasi dan Loss pada Tahap Fine-Tuning

3.2. Evaluasi Model

Tahap evaluasi dilakukan menggunakan data validasi sebanyak 837 citra yang tidak digunakan selama proses pelatihan. Evaluasi bertujuan untuk mengukur kemampuan model MobileNetV2 dalam mengklasifikasikan citra daun jagung berdasarkan *confusion matrix* dan *classification report*. *Confusion matrix* digunakan untuk menunjukkan kesesuaian antara hasil prediksi model dan label aktual pada setiap kelas. Hasil *confusion matrix* ditampilkan pada Gambar 4.



Gambar 4. Confusion Matrix

Berdasarkan Gambar 4, model mampu mengklasifikasikan sebagian besar citra pada setiap kelas dengan benar. Seluruh citra pada kelas Healthy berhasil dikenali dengan tepat, yaitu sebanyak 225 citra. Pada kelas Common Rust, sebanyak 257 dari 261 citra berhasil diklasifikasikan dengan benar. Sementara itu, kesalahan klasifikasi masih ditemukan pada kelas Blight dan Gray Leaf Spot. Sebanyak 18 citra Blight diprediksi sebagai Gray Leaf Spot, sedangkan 12 citra Gray Leaf Spot diprediksi sebagai Blight. Kesalahan tersebut menunjukkan bahwa kedua kelas masih memiliki karakteristik visual yang serupa sehingga lebih sulit dibedakan oleh model dibandingkan kelas lainnya.

Untuk memperoleh gambaran kinerja model secara kuantitatif, dilakukan perhitungan metrik *precision*, *recall*, dan *F1-score* untuk setiap kelas. Hasil evaluasi disajikan pada Tabel 4.

Tabel 4. Hasil Evaluasi Model MobileNetV2

Kelas	Precision	Recall	F1-Score	Support
Blight	0,93	0,91	0,92	235
Common Rust	0,99	0,98	0,99	261
Gray Leaf Spot	0,85	0,89	0,87	116
Healthy	0,99	1,00	1,00	225
Accuracy			0,96	837
Macro Average	0,94	0,95	0,94	837
Weighted Average	0,96	0,96	0,96	837

Berdasarkan Tabel 4, model MobileNetV2 dengan teknik *fine-tuning* memperoleh akurasi keseluruhan sebesar 96%. Kelas Healthy memiliki nilai *recall* sebesar 1,00, yang menunjukkan bahwa seluruh citra daun sehat pada data validasi berhasil diklasifikasikan dengan benar. Selain itu, kelas Common Rust memperoleh nilai *precision*, *recall*, dan *F1-score* yang tinggi, yaitu masing-masing sebesar 0,99, 0,98, dan 0,99. Di sisi lain, kelas Gray Leaf Spot memiliki nilai *precision* sebesar 0,85, *recall* sebesar 0,89, dan *F1-score* sebesar 0,87, yang merupakan nilai terendah dibandingkan kelas lainnya. Hasil tersebut sejalan dengan *confusion matrix* yang menunjukkan masih adanya kesalahan klasifikasi antara kelas Gray Leaf Spot dan Blight. Secara keseluruhan, nilai *macro average* sebesar 0,94 dan *weighted average* sebesar 0,96 menunjukkan bahwa model mampu memberikan kinerja yang baik pada keempat kelas penyakit daun jagung.

3.3. Analisis Kelemahan Model

Meskipun model MobileNetV2 dengan teknik *fine-tuning* memperoleh akurasi keseluruhan sebesar 96%, hasil evaluasi menunjukkan beberapa keterbatasan yang masih ditemukan pada proses klasifikasi. Berdasarkan *confusion matrix*, kesalahan klasifikasi paling banyak terjadi antara kelas Blight dan Gray Leaf Spot. Sebanyak 18 citra Blight diprediksi sebagai Gray Leaf

Spot, sedangkan 12 citra Gray Leaf Spot diprediksi sebagai Blight. Hasil tersebut menunjukkan bahwa kedua kelas memiliki karakteristik visual yang relatif serupa sehingga lebih sulit dibedakan dibandingkan kelas lainnya. Selain itu, penggunaan ukuran citra 224×224 piksel sebagai masukan MobileNetV2 juga dapat mengurangi detail visual tertentu yang berpotensi membantu proses pembedaan kedua kelas tersebut.

Selama tahap *fine-tuning*, kurva pelatihan menunjukkan bahwa nilai *training loss* terus menurun, sedangkan *validation loss* mulai meningkat setelah *epoch* ke-7. Kondisi ini mengindikasikan adanya kecenderungan *overfitting* pada beberapa *epoch* terakhir. Pada penelitian ini, proses pelatihan dilakukan tanpa menerapkan *data augmentation*, sehingga variasi data pelatihan terbatas pada citra asli yang tersedia. Oleh karena itu, penggunaan *data augmentation* dapat dipertimbangkan pada penelitian selanjutnya untuk meningkatkan variasi data pelatihan dan mengurangi kecenderungan *overfitting*.

Keterbatasan lainnya berkaitan dengan distribusi jumlah data pada setiap kelas. Dataset yang digunakan memiliki jumlah sampel yang berbeda untuk masing-masing kelas, dengan kelas Gray Leaf Spot memiliki jumlah data paling sedikit. Kondisi tersebut dapat menjadi salah satu faktor yang memengaruhi kemampuan model dalam mengenali karakteristik kelas tersebut. Hal ini terlihat dari nilai *precision* sebesar 0,85 dan *F1-score* sebesar 0,87, yang merupakan nilai terendah dibandingkan kelas lainnya. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penggunaan dataset dengan distribusi kelas yang lebih seimbang atau menerapkan teknik penanganan *class imbalance* untuk meningkatkan kinerja model pada kelas minoritas.

3.4. Pembahasan

Hasil penelitian menunjukkan bahwa penerapan MobileNetV2 dengan teknik *fine-tuning* menghasilkan akurasi klasifikasi sebesar 96% pada dataset penyakit daun jagung. Peningkatan akurasi setelah tahap *fine-tuning* menunjukkan bahwa pelatihan kembali sebagian lapisan konvolusi mampu meningkatkan kemampuan model dalam mengenali karakteristik citra dibandingkan ketika hanya menggunakan tahap *feature extraction*. Selain itu, model mampu memberikan nilai *precision*, *recall*, dan *F1-score* yang tinggi pada sebagian besar kelas, meskipun masih ditemukan kesalahan klasifikasi antara kelas Blight dan Gray Leaf Spot.

Apabila dibandingkan dengan penelitian terdahulu, hasil yang diperoleh menunjukkan bahwa MobileNetV2 mampu memberikan kinerja yang sebanding dengan beberapa arsitektur CNN lainnya. Akhyari dkk. (2021) melaporkan akurasi sekitar 98% menggunakan VGG-16, sedangkan Kusumastuti dkk. (2024) memperoleh akurasi sekitar 97% menggunakan EfficientNetB2. Meskipun akurasi pada penelitian ini sedikit lebih rendah, MobileNetV2 memiliki jumlah parameter yang lebih sedikit sehingga memerlukan sumber daya komputasi yang lebih rendah dibandingkan kedua arsitektur tersebut.

Hasil penelitian ini juga menunjukkan peningkatan dibandingkan penelitian Dewi dkk. (2023) yang menggunakan arsitektur MobileNet dan memperoleh akurasi sebesar 90,75%. Perbedaan tersebut mengindikasikan bahwa penerapan *fine-tuning* pada sebagian lapisan konvolusi memberikan pengaruh terhadap peningkatan kemampuan model dalam mengenali karakteristik penyakit daun jagung. Namun demikian, penelitian ini belum melakukan perbandingan langsung antara model dengan dan tanpa *fine-tuning*, sehingga besarnya pengaruh teknik tersebut masih perlu dikaji lebih lanjut.

Berdasarkan hasil evaluasi, model memiliki nilai *recall* sebesar 1,00 pada kelas Healthy dan nilai *F1-score* sebesar 0,99 pada kelas Common Rust. Hasil tersebut menunjukkan bahwa model mampu mengklasifikasikan kedua kelas tersebut dengan baik. Di sisi lain, kesalahan klasifikasi masih ditemukan pada kelas Blight dan Gray Leaf Spot, sehingga peningkatan jumlah data pada kelas minoritas atau penerapan teknik *data augmentation* dapat dipertimbangkan pada penelitian selanjutnya untuk meningkatkan kemampuan model dalam membedakan kedua kelas tersebut.

4 CONCLUSION

Penelitian ini menerapkan metode *Transfer Learning* menggunakan arsitektur MobileNetV2 dengan teknik *fine-tuning* untuk mengklasifikasikan empat kondisi daun jagung, yaitu Blight, Common Rust, Gray Leaf Spot, dan Healthy. Hasil evaluasi menunjukkan bahwa model memperoleh akurasi sebesar 96%, dengan nilai *precision*, *recall*, dan *F1-score* yang tinggi pada sebagian besar kelas. Hasil tersebut menunjukkan bahwa MobileNetV2 dengan teknik *fine-tuning* mampu mengklasifikasikan citra penyakit daun jagung dengan baik menggunakan dataset yang digunakan pada penelitian ini.

Berdasarkan hasil *confusion matrix*, kesalahan klasifikasi masih ditemukan antara kelas Blight dan Gray Leaf Spot, yang menunjukkan bahwa kedua kelas memiliki karakteristik visual yang relatif serupa. Selain itu, selama tahap *fine-tuning* terdapat kecenderungan *overfitting* pada beberapa *epoch* terakhir. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penggunaan teknik penanganan *class imbalance*, penerapan *data augmentation*, serta pengujian model pada dataset yang lebih beragam untuk meningkatkan kemampuan generalisasi model.

REFERENCES

- [1] R. T. Wahyuningrum, R. Erfian, A. Kusumaningsih, and H. P. A. Tjahyaningtijas, "Klasifikasi Penyakit Daun Jagung Menggunakan Model Deep Learning EfficientNetB5," *J. Pekommas*, vol. 10, no. 1, pp. 1–8, 2025, doi: 10.56873/jpkm.v9i1.5322.
- [2] Mochammad Faisal Nur Sayyid, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode CNN Dengan Image Processing HE Dan CLAHE," *J. Tek. Inform. dan Teknol. Inf.*, vol. 4, no. 1, pp. 86–95, 2024, doi: 10.55606/jutiti.v4i1.3425.
- [3] I. P. Putra, Rusbandi, and D. Alamsyah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network," *J. Algoritma*, vol. 2, no. 2, pp. 28–33, 2022, doi: 10.56211/sudo.v2i1.227.
- [4] F. Sarasati, F. Septia Nugraha, and U. Radiyah, "Pemanfaatan Metode Deep Learning untuk Klasifikasi Penyakit pada Tanaman Jagung," *J. Infortech*, vol. 1, no. 1, pp. 133–138, 2022, [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/infortech%0Ahttps://ejournal.bsi.ac.id/ejurnal/index.php/infortech/article/view/13898>
- [5] M. W. Akhyari, A. Suyoto, and F. W. Wibowo, "Klasifikasi Penyakit Pada Daun Jagung Menggunakan Convolutional Neural Network," *J. Inf. J. Penelit. dan Pengabd. Masy.*, vol. 7, no. 2, pp. 3–6, 2021.
- [6] R. Suhendra, I. Juliwardi, and S. Sanusi, "Identifikasi dan Klasifikasi Penyakit Daun Jagung Menggunakan Support Vector Machine," *J. Teknol. Inf.*, vol. 1, no. 1, pp. 29–35, 2022, doi: 10.35308/v1i1.5520.
- [7] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *sudo J. Tek. Inform.*, vol. 2, no. 1, pp. 28–33, 2023, doi: 10.56211/sudo.v2i1.227.
- [8] A. L. Hermawan, "Klasifikasi Penyakit Daun Jagung Menggunakan Lightweight Convolutional Neural Network," *JIIFKOM (Jurnal Ilm. Inform. dan Komputer)*, vol. 2, no. 2, pp. 1–7, 2023, doi: 10.51901/jiifkom.v2i2.347.
- [9] R. Kusumastuti, T. D. Putra, and Z. Z. Yudam, "KLASIFIKASI CITRA PENYAKIT DAUN JAGUNG MENGGUNAKAN ALGORITMA CNN EFFICIENTNET," *Multitek Indones. J. Ilm.*, vol. 17, no. 1, pp. 60–68, 2023.
- [10] D. A. Iskandar and A. Salam, "Evaluasi Performa Oversampling dan Augmentasi pada Klasifikasi Penyakit Kulit Menerapkan Convolutional Neural Network," *J. Media Inform. Budidarma*, vol. 8, no. 1, p. 240, 2024, doi: 10.30865/mib.v8i1.7119.
- [11] D. Marcella, Y. Yohannes, and S. Devella, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Dengan Arsitektur VGG-19," *J. Algoritma*, vol. 3, no. 1, pp. 60–70, 2022, doi: 10.35957/algoritme.v3i1.3331.
- [12] F. Reynaldi Valerian, M. Syarif, and D. Abdul Fatah, "Klasifikasi Tingkat Obesitas Menggunakan Metode Gbm Dan Confusion Matrix," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, pp. 2242–2249, 2025, doi: 10.36040/jati.v9i2.13062.