

KLASIFIKASI PENYAKIT TANAMAN PADI MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR MOBILNETV2

Eko Fuji Pangestu^{1*}, Bambang Irawan²

^{1,2}Universitas Muhadi Setiabudi; Jalan P. Diponegoro KM 2, Pesantunan, Wanasari, Brebes, Jawa Tengah 52212; Telp. (0283) 6199000 Fax: (0283) 6199001

Keywords:

rice leaf disease, image classification, deep learning, MobileNetV2.

Correspondent Email:

fujieko045@gmail.com



Copyright © [JITET](#) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstrak. Serangan penyakit pada tanaman padi menjadi salah satu penyebab utama menurunnya hasil produksi pertanian. Proses identifikasi penyakit secara konvensional umumnya membutuhkan keahlian khusus dan tidak selalu efektif dilakukan di lapangan. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit daun padi berbasis citra digital menggunakan metode *Deep Learning* dengan arsitektur *Convolutional Neural Network* MobileNetV2. Dataset yang digunakan terdiri dari lima kelas, yaitu penyakit bakteri, bercak coklat, blas, tungro, dan daun sehat, yang diperoleh dari platform Roboflow. Tahapan penelitian meliputi pengumpulan data, *pre-processing* citra, pelatihan model dengan pendekatan *transfer learning*, serta evaluasi kinerja model. Hasil pengujian menunjukkan bahwa model mampu mencapai akurasi sebesar 93,46% dengan performa yang baik pada sebagian besar kelas. Meskipun masih terdapat kesalahan klasifikasi pada kelas dengan gejala visual yang serupa, model yang dihasilkan memiliki potensi untuk digunakan sebagai sistem pendukung identifikasi penyakit tanaman padi secara otomatis dan efisien.

Abstract. Diseases affecting rice plants are one of the major factors contributing to decreased agricultural productivity and potential losses for farmers. Conventional disease identification generally relies on expert knowledge and is often impractical to perform accurately and efficiently in the field. This study aims to develop an image-based classification system for rice leaf diseases using a Deep Learning approach with a Convolutional Neural Network architecture, specifically MobileNetV2. The dataset consists of five rice leaf condition classes, namely bacterial disease, brown spot, blast, tungro, and healthy leaves, obtained from the Roboflow platform. The research methodology includes data collection, image pre-processing, model training using a transfer learning approach, and performance evaluation. Experimental results demonstrate that the proposed MobileNetV2 model achieves an accuracy of 93.46% and shows strong performance across most disease categories. Although misclassification still occurs among classes with similar visual characteristics, the results indicate that the developed model has significant potential as an efficient and automated decision-support system for rice plant disease identification.

1. PENDAHULUAN

Sektor pertanian memiliki peran yang sangat penting dalam menjaga keberlangsungan ketahanan pangan nasional, khususnya di

Indonesia yang masih bergantung pada hasil pertanian sebagai sumber utama kebutuhan pangan. Salah satu komoditas strategis yang memiliki posisi sentral adalah padi, mengingat

beras merupakan bahan pangan pokok yang dikonsumsi oleh mayoritas penduduk. Namun, produktivitas tanaman padi tidak selalu berada pada kondisi optimal karena dipengaruhi oleh berbagai faktor pembatas, salah satunya adalah serangan penyakit tanaman. Penanganan penyakit yang tidak dilakukan secara tepat waktu dan akurat dapat menyebabkan kegagalan panen, yang pada akhirnya berdampak pada penurunan produksi padi serta berkurangnya pendapatan petani [1].

Tanaman padi merupakan komoditas yang paling banyak dibudidayakan di Indonesia seiring dengan tingginya tingkat konsumsi beras oleh masyarakat. Serangan penyakit tanaman sering kali menjadi penyebab utama menurunnya hasil panen. Padi yang terserang penyakit dapat mengalami penurunan baik dari segi kualitas maupun kuantitas hasil produksi, bahkan dalam kondisi tertentu dapat menimbulkan kerugian yang signifikan akibat gagal panen. Oleh karena itu, kemampuan dalam mengenali serta mengidentifikasi jenis penyakit yang menyerang tanaman padi secara akurat menjadi aspek yang sangat penting agar petani dapat menentukan langkah pengendalian dan penanganan yang sesuai [2].

Selain permasalahan penyakit tanaman, peningkatan jumlah penduduk yang terus terjadi juga menjadi faktor yang mendorong terjadinya konversi lahan pertanian. Data menunjukkan bahwa jumlah penduduk Indonesia mengalami peningkatan yang cukup signifikan, dari 237,6 juta jiwa pada tahun 2010 menjadi sekitar 261 juta jiwa pada tahun 2016. Pertumbuhan tersebut memberikan tekanan terhadap ketersediaan lahan pertanian dalam waktu yang relatif singkat. Di sisi lain, sekitar 80% masyarakat Indonesia menjadikan nasi sebagai makanan pokok, yang menegaskan karakter Indonesia sebagai negara agraris dengan ketergantungan tinggi terhadap produksi padi. Kondisi ini menuntut adanya upaya inovatif untuk meningkatkan atau setidaknya menjaga stabilitas produksi padi guna mendukung ketahanan pangan nasional [3].

Perkembangan teknologi telah merambah hampir seluruh sektor kehidupan, termasuk bidang pertanian. Pemanfaatan teknologi mampu membantu meningkatkan efisiensi kerja, mempercepat proses pengambilan keputusan, serta meminimalkan kesalahan

manusia. Oleh sebab itu, diperlukan suatu sistem berbasis teknologi yang dapat mendeteksi penyakit pada daun padi dan memberikan informasi terkait kondisi serta tingkat kerusakan tanaman kepada petani [4]. Seiring dengan kemajuan teknologi informasi dan komputasi, proses identifikasi penyakit tanaman kini dapat dilakukan dengan memanfaatkan *artificial intelligence*, khususnya melalui pendekatan pengolahan citra dan pengenalan pola.

Bidang *artificial intelligence* mengalami perkembangan yang sangat pesat, terutama dengan hadirnya metode *machine learning* yang kemudian berkembang menjadi cabang ilmu yang lebih spesifik, yaitu *deep learning*. Pendekatan *deep learning* dinilai memiliki performa yang lebih unggul dibandingkan metode *machine learning* konvensional. Salah satu algoritma *deep learning* yang banyak digunakan dan menunjukkan kinerja tinggi dalam pengolahan citra adalah *Convolutional Neural Network* (CNN). CNN telah terbukti memberikan hasil yang sangat baik pada berbagai aplikasi nyata, termasuk dalam tugas klasifikasi citra [5]. Keunggulan utama CNN terletak pada kemampuannya dalam mengekstraksi fitur secara otomatis serta menangani data dengan skala besar dan kompleks secara efektif [6].

Pendekatan *deep learning* berbasis CNN telah banyak dimanfaatkan dalam penelitian klasifikasi citra karena kemampuannya dalam mengekstraksi informasi visual secara mendalam. Salah satu arsitektur CNN yang dikenal memiliki performa baik dalam klasifikasi penyakit tanaman adalah *EfficientNet*. Penelitian yang dilakukan oleh Milano dan rekan-rekannya menerapkan arsitektur *EfficientNet-B6* untuk mengidentifikasi penyakit pada daun padi berbasis citra digital. Dengan memanfaatkan ribuan citra daun padi yang dikelompokkan ke dalam beberapa kategori kondisi daun, penelitian tersebut menghasilkan tingkat akurasi terbaik sebesar 77,05%, disertai nilai *precision*, *recall*, dan *f1-score* yang relatif seimbang. Evaluasi menggunakan kurva *ROC* juga menunjukkan nilai *AUC* yang tinggi, yang mengindikasikan kemampuan model dalam membedakan karakteristik visual antar kelas penyakit [7].

Meskipun demikian, hasil penelitian tersebut masih menunjukkan adanya keterbatasan, terutama dalam membedakan kelas penyakit yang memiliki kemiripan karakteristik visual. Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penggunaan arsitektur *MobileNetV2* sebagai alternatif model CNN yang lebih ringan dan efisien dari sisi komputasi. Berbeda dengan penelitian sebelumnya, fokus penelitian ini diarahkan pada klasifikasi penyakit daun padi dengan jumlah kelas yang lebih beragam, serta penerapan teknik *pre-processing*, *data augmentation*, dan *transfer learning* yang lebih optimal. Pendekatan ini diharapkan mampu meningkatkan kemampuan generalisasi model dan menghasilkan sistem identifikasi penyakit daun padi yang lebih akurat, stabil, serta aplikatif dalam mendukung pengambilan keputusan pengendalian penyakit di sektor pertanian.

2. TINJAUAN PUSTAKA

2.1. Penyakit Tanaman Padi

Padi merupakan salah satu komoditas pertanian strategis di Indonesia yang memiliki tingkat kerentanan tinggi terhadap berbagai serangan penyakit. Beberapa penyakit utama, seperti *blast*, *brown spot*, *tungro*, serta infeksi yang disebabkan oleh bakteri, dapat menimbulkan perubahan pada struktur daun, menurunkan mutu hasil panen, bahkan berujung pada kegagalan produksi. Manifestasi serangan penyakit umumnya tampak pada bagian daun, antara lain berupa perubahan warna, munculnya bercak, hingga kerusakan jaringan tanaman. Oleh karena itu, daun menjadi bagian tanaman yang sangat penting sebagai indikator dalam proses pengenalan dan klasifikasi penyakit. Upaya deteksi dini terhadap penyakit pada tanaman padi sangat dibutuhkan agar langkah pengendalian dapat dilakukan secara cepat dan tepat, sehingga potensi kerugian hasil panen dapat ditekan seminimal mungkin.

2.2. Pengolahan Citra Digital dalam Pertanian

Pengolahan citra digital telah banyak dimanfaatkan dalam sektor pertanian sebagai pendekatan otomatis untuk memantau serta menganalisis kondisi tanaman. Melalui teknologi ini, informasi visual dari citra

tanaman seperti karakteristik warna, tekstur, dan bentuk dapat diekstraksi dan digunakan sebagai dasar dalam proses klasifikasi. Dibandingkan dengan metode identifikasi secara manual atau konvensional, pengolahan citra digital menawarkan keunggulan dalam hal efisiensi waktu, konsistensi hasil, serta kemampuan dalam menangani data berskala besar. Seiring dengan pesatnya perkembangan teknologi komputasi dan *artificial intelligence*, penerapan pengolahan citra digital dalam identifikasi penyakit tanaman menjadi semakin relevan dan berpotensi memberikan solusi yang lebih akurat serta andal.

2.3. Deep Learning dan Convolutional Neural Network

Deep learning merupakan bagian dari *machine learning* yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan untuk mempelajari representasi data secara mendalam dan otomatis. Dalam bidang pengolahan citra, salah satu arsitektur yang paling umum digunakan adalah *Convolutional Neural Network* (CNN). CNN dirancang untuk mengekstraksi fitur visual secara bertahap melalui proses konvolusi, sehingga mampu mengenali pola-pola kompleks yang terdapat pada citra digital. Keunggulan utama CNN terletak pada kemampuannya dalam melakukan pembelajaran fitur secara otomatis tanpa memerlukan perancangan fitur manual. Oleh karena itu, CNN banyak diterapkan pada berbagai bidang, termasuk klasifikasi citra medis, pertanian, serta aplikasi industri.

2.4. Arsitektur MobileNetV2

MobileNetV2 merupakan salah satu pengembangan arsitektur CNN yang difokuskan pada efisiensi komputasi serta pengurangan jumlah parameter model. Arsitektur ini mengadopsi konsep *inverted residual* dan *linear bottleneck* yang bertujuan untuk menekan kompleksitas perhitungan sekaligus mempertahankan tingkat akurasi yang optimal. Dengan karakteristik tersebut, *MobileNetV2* sangat sesuai untuk diimplementasikan pada perangkat dengan keterbatasan sumber daya, seperti perangkat bergerak maupun *embedded system*. Dalam penerapan klasifikasi penyakit tanaman, *MobileNetV2* telah menunjukkan kinerja yang kompetitif dengan waktu pelatihan yang relatif

lebih singkat dibandingkan arsitektur CNN konvensional, namun tetap mampu menghasilkan tingkat akurasi yang memadai.

2.5. Transfer Learning dalam Klasifikasi Citra

Transfer learning merupakan metode pembelajaran yang memanfaatkan model yang telah dilatih sebelumnya menggunakan dataset berskala besar, seperti *ImageNet*, untuk menyelesaikan permasalahan baru dengan jumlah data yang lebih terbatas. Pendekatan ini memungkinkan model memanfaatkan pengetahuan awal berupa fitur-fitur umum citra, sehingga proses pelatihan menjadi lebih efisien dan stabil. Dalam penelitian klasifikasi penyakit pada daun padi, *transfer learning* berperan penting dalam meningkatkan kinerja model sekaligus mengurangi kemungkinan terjadinya *overfitting*. Melalui proses *fine-tuning* pada lapisan tertentu, model dapat menyesuaikan parameter pembelajarannya agar lebih relevan dengan karakteristik visual spesifik dari penyakit daun padi.

3. METODE PENELITIAN

Penelitian ini bertujuan untuk merancang dan mengembangkan model klasifikasi citra penyakit pada daun padi dengan tingkat akurasi yang optimal menggunakan arsitektur *MobileNetV2*. Arsitektur *MobileNetV2* merupakan pengembangan dari *convolutional neural network* yang difokuskan pada efisiensi komputasi melalui penerapan konsep *inverted residual* dan *linear bottleneck*. Pendekatan tersebut memungkinkan pengurangan kompleksitas model serta kebutuhan memori, tanpa memberikan dampak yang signifikan terhadap kinerja klasifikasi citra [8].

Pemilihan arsitektur *MobileNetV2* didasarkan pada karakteristiknya sebagai model yang ringan, efisien, dan tetap mampu memberikan performa yang baik dalam berbagai tugas klasifikasi citra. Selain itu, arsitektur ini mendukung penerapan *transfer learning*, sehingga proses pelatihan model dapat dilakukan secara lebih cepat dan stabil, terutama ketika ketersediaan data latih relatif terbatas.

Pengembangan sistem klasifikasi penyakit daun padi dalam penelitian ini dilakukan melalui serangkaian tahapan yang dirancang secara sistematis agar proses pembangunan dan

evaluasi model berjalan secara terstruktur. Tahapan penelitian meliputi pengumpulan data, tahap *pre-processing*, tahap *processing*, serta tahap pengujian dan evaluasi. Setiap tahapan saling berkaitan dan berkontribusi dalam menghasilkan model klasifikasi yang andal dan optimal.

3.1. Tahap Pengumpulan Data

Proses pengumpulan data pada penelitian ini dilakukan dengan memanfaatkan platform *Roboflow*, yaitu platform berbasis web yang banyak digunakan dalam penelitian *computer vision* untuk pengelolaan dataset citra. *Roboflow* menyediakan dataset yang telah melalui proses anotasi dan standarisasi, serta mendukung pengaturan data sebelum digunakan dalam pelatihan model *deep learning*. Keandalan platform ini tercermin dari pemanfaatan dataset multi-domain yang tersedia pada *Roboflow Universe*, yang telah digunakan dalam berbagai penelitian untuk evaluasi model *vision-language* [9].

Dataset daun padi yang digunakan dalam penelitian ini diperoleh dari salah satu proyek publik yang tersedia pada platform *Roboflow*. Dataset tersebut berisi kumpulan citra daun padi dengan berbagai kondisi penyakit yang telah dilengkapi label tervalidasi. Secara keseluruhan, dataset terdiri dari lima kelas, yaitu penyakit bakteri, bercak coklat, blas, tungro, serta daun padi dalam kondisi sehat. Seluruh citra telah melalui proses anotasi dan verifikasi oleh penyedia dataset, sehingga label yang diberikan sesuai dengan karakteristik visual yang terdapat pada masing-masing citra.

Setelah dataset ditentukan, data diunduh melalui platform *Roboflow* dalam format *image classification* dan secara otomatis disusun dalam struktur direktori yang terorganisasi. Selanjutnya, dataset dibagi ke dalam tiga subset, yaitu data latih (*training*), data validasi (*validation*), dan data uji (*testing*). Pembagian data dilakukan menggunakan konfigurasi standar dari *Roboflow* dengan proporsi 70% untuk data latih, 20% untuk data validasi, dan 10% untuk data pengujian.

Tabel 3.1. Pengelompokan data sesuai kategori

No	Kategori	Jumlah
1	Bakteri	1.284
2	Bercak coklat	1.600
3	Blas	1.600
4	Sehat	1.600
5	Tungro	1.308
Total		7.392

3.2. Tahap Pre-processing

Tahap *pre-processing* dilakukan untuk memastikan bahwa seluruh citra daun padi memiliki format dan karakteristik yang seragam sebelum digunakan dalam proses pelatihan model. Pada tahap ini, setiap citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan spesifikasi masukan arsitektur *MobileNetV2*. Selain itu, nilai piksel pada citra dinormalisasi ke dalam rentang 0–1 dengan tujuan menstabilkan distribusi data dan meningkatkan efisiensi proses pembelajaran pada model *deep learning* [10]. Penyeragaman tersebut diperlukan agar model menerima masukan yang konsisten dan tidak terpengaruh oleh perbedaan resolusi atau skala citra asli.

Tahapan selanjutnya adalah penerapan *data augmentation* untuk memperkaya variasi data pelatihan dan meningkatkan kemampuan generalisasi model. Teknik augmentasi yang digunakan meliputi rotasi dalam sudut kecil, pergeseran citra secara horizontal dan vertikal, pembesaran (*zoom*), serta *horizontal flip*. Transformasi ini dipilih karena mampu menghasilkan variasi citra yang tetap realistis tanpa mengubah karakteristik utama objek, sehingga efektif dalam menekan risiko *overfitting* [11]. Selain itu, label kelas pada dataset dikonversi ke dalam format *one-hot encoding* agar sesuai dengan kebutuhan keluaran fungsi aktivasi *softmax* pada skema klasifikasi multi-kelas.

Dataset yang diperoleh dari platform *Roboflow* telah dibagi ke dalam tiga subset, yaitu *training*, *validation*, dan *testing*. Pemisahan ini bertujuan untuk membedakan data yang digunakan dalam proses

pembelajaran dengan data yang digunakan untuk evaluasi, sehingga kinerja model dapat diukur secara objektif dan terhindar dari bias. Melalui rangkaian proses *pre-processing* tersebut, data citra menjadi lebih siap untuk diproses oleh model klasifikasi dan mendukung proses pelatihan yang lebih optimal.

3.3. Tahap Processing

Tahap *processing* merupakan bagian utama dalam penelitian ini karena pada tahap inilah model klasifikasi citra penyakit daun padi dirancang, dilatih, dan dioptimalkan. Proses ini diawali dengan pemanfaatan arsitektur *MobileNetV2* sebagai *base model*. Arsitektur tersebut dipilih karena memiliki struktur jaringan yang efisien, jumlah parameter yang relatif kecil, serta kemampuan yang baik dalam tugas pengenalan citra. Selain itu, *MobileNetV2* mendukung penerapan *transfer learning*, sehingga bobot awal hasil pelatihan pada dataset *ImageNet* dapat digunakan sebagai dasar ekstraksi fitur sebelum disesuaikan dengan karakteristik citra penyakit daun padi.

Dalam tahap pengembangan model, lapisan-lapisan awal pada *MobileNetV2* dibekukan (*frozen*) untuk mempertahankan fitur umum yang telah dipelajari sebelumnya, sedangkan sekitar 20 lapisan terakhir dibuka untuk proses *fine-tuning*. Pendekatan ini memungkinkan model untuk mempelajari fitur-fitur yang lebih spesifik terhadap karakteristik visual daun padi, seperti perubahan warna, pola bercak, bentuk kerusakan, serta tekstur yang menjadi ciri khas masing-masing kelas penyakit.

Pada bagian akhir jaringan, ditambahkan beberapa lapisan klasifikasi yang terdiri dari *Global Average Pooling*, *Batch Normalization*, serta lapisan *Dense* dengan ukuran 256 dan 128 neuron yang menggunakan fungsi aktivasi *ReLU*. Untuk meminimalkan risiko *overfitting*, disisipkan pula lapisan *Dropout*. Lapisan keluaran menggunakan fungsi aktivasi *softmax* dengan lima neuron yang disesuaikan dengan jumlah kelas penyakit yang diklasifikasikan.

Proses pelatihan model dilakukan menggunakan *optimizer Adam* dengan nilai *learning rate* sebesar 0.0001 guna menjaga kestabilan pembaruan bobot selama pelatihan. Fungsi *loss* yang digunakan adalah *categorical crossentropy* karena penelitian ini menangani permasalahan klasifikasi multi-kelas. Selain itu, diterapkan mekanisme *EarlyStopping* untuk

menghentikan pelatihan ketika nilai *validation loss* tidak mengalami peningkatan dalam beberapa epoch, serta *ReduceLROnPlateau* untuk menyesuaikan *learning rate* secara adaptif apabila kinerja model menunjukkan stagnasi. Proses pelatihan dilakukan menggunakan data latih dan dipantau melalui data validasi untuk memastikan model mampu mempelajari pola penyakit secara efektif tanpa mengalami *overfitting*.

Tahap *processing* ini berperan penting dalam menghasilkan model klasifikasi yang akurat dan stabil. Dengan mengombinasikan arsitektur *MobileNetV2*, pendekatan *transfer learning*, strategi *fine-tuning* yang terarah, serta mekanisme optimisasi yang tepat, sistem yang dikembangkan diharapkan mampu memberikan performa optimal dalam mengidentifikasi jenis penyakit daun padi berdasarkan citra masukan.

3.4. Tahap Uji Coba dan Validasi

Tahap uji coba dan validasi dilakukan untuk memastikan bahwa model klasifikasi yang telah dikembangkan mampu memberikan kinerja yang optimal ketika diaplikasikan pada data yang tidak terlibat dalam proses pelatihan. Pada tahap ini, model dievaluasi menggunakan *testing set* yang telah dipisahkan dari data latih dan data validasi, sehingga penilaian performa dapat dilakukan secara objektif serta terhindar dari risiko *data leakage*. Data uji digunakan untuk mengukur kemampuan model dalam mengklasifikasikan lima kelas kondisi daun padi, yaitu penyakit bakteri, bercak coklat, blas, tungro, serta daun padi sehat.

Penilaian kinerja model dilakukan dengan menghitung sejumlah metrik evaluasi, meliputi akurasi, nilai *loss*, *precision*, *recall*, dan *f1-score*. Nilai akurasi dan *loss* diperoleh melalui proses evaluasi model secara langsung, sedangkan metrik *precision*, *recall*, dan *f1-score* dihitung menggunakan *classification report* guna memberikan gambaran yang lebih rinci terkait kemampuan model dalam mengklasifikasikan masing-masing kelas penyakit. Penggunaan kombinasi metrik tersebut penting untuk mengevaluasi kinerja model secara komprehensif, terutama pada permasalahan klasifikasi multi-kelas yang memiliki karakteristik visual antar kelas yang relatif serupa.

Selain itu, analisis kesalahan prediksi dilakukan dengan memanfaatkan *confusion*

matrix. Matriks ini berfungsi untuk mengidentifikasi kelas-kelas yang paling sering mengalami kesalahan klasifikasi (*misclassification*), sehingga kelemahan model dalam membedakan jenis penyakit tertentu dapat diketahui secara lebih jelas.

Tidak hanya terbatas pada evaluasi kuantitatif, tahap uji coba dan validasi juga mencakup visualisasi hasil prediksi model terhadap sejumlah citra uji. Visualisasi ini bertujuan untuk menilai kesesuaian antara label hasil prediksi dengan kondisi visual citra secara langsung, sehingga dapat memberikan gambaran tambahan terkait tingkat interpretabilitas dan keandalan model [12]. Dengan pendekatan tersebut, evaluasi model tidak hanya didasarkan pada metrik numerik, tetapi juga mempertimbangkan kualitas hasil prediksi secara visual. Secara keseluruhan, tahapan ini memastikan bahwa model yang dikembangkan memiliki tingkat reliabilitas yang baik serta mampu mengklasifikasikan penyakit daun padi secara akurat pada berbagai variasi kondisi citra.

4. HASIL DAN PEMBAHASAN

4.1. Tahap Pre-processing

Tahap *pre-processing* dilakukan untuk mempersiapkan citra daun padi sebelum digunakan dalam proses pelatihan model klasifikasi. Pada tahap awal, dilakukan eksplorasi dataset melalui visualisasi citra berdasarkan masing-masing kelas penyakit, sebagaimana disajikan pada Gambar 4.1. Visualisasi ini bertujuan untuk memastikan bahwa dataset memiliki keberagaman pola visual yang memadai, mencakup variasi warna daun, tekstur permukaan, serta bentuk dan distribusi bercak penyakit.

Selanjutnya, seluruh citra diproses agar memiliki format masukan yang seragam. Proses ini meliputi penyesuaian ukuran citra menjadi resolusi 224×224 piksel serta normalisasi nilai piksel ke dalam rentang 0–1. Penyeragaman ukuran dan skala nilai piksel dilakukan untuk memastikan kesesuaian data masukan dengan arsitektur *MobileNetV2* serta meningkatkan kestabilan proses pembelajaran model selama pelatihan.

Selain itu, diterapkan teknik *data augmentation* pada citra pelatihan untuk memperkaya variasi data dan menekan risiko

overfitting. Teknik augmentasi yang digunakan meliputi rotasi ringan, pergeseran posisi citra, pembesaran (*zoom*), serta pembalikan horizontal. Rangkaian tahapan *pre-processing* ini menghasilkan data citra yang lebih representatif dan siap digunakan pada proses pelatihan model klasifikasi [13].



Gambar 4.1. Gambar dari dataset hasil observasi yang sudah ditentukan variabelnya sesuai kategori

4.2. Tahap Processing

Tahap *processing* merupakan tahap pelatihan model klasifikasi setelah seluruh citra melalui proses *pre-processing*. Dataset pada penelitian ini dibagi ke dalam tiga subset, yaitu *training*, *validation*, dan *test*, dengan rasio tertentu agar proses pembelajaran, validasi, dan pengujian model dapat dilakukan secara terpisah [14]. Pembagian ini bertujuan untuk memastikan bahwa setiap tahapan evaluasi dilakukan secara independen, sehingga hasil yang diperoleh bersifat objektif dan tidak bias.

Distribusi jumlah citra pada setiap kelas dan subset ditampilkan pada Tabel 4.2. Pembagian data yang proporsional pada masing-masing kelas dilakukan untuk memastikan bahwa model memperoleh variasi sampel yang memadai, sehingga mampu mempelajari karakteristik visual dari setiap jenis penyakit daun padi secara lebih optimal.

Tabel 4.2. Distribusi Dataset Citra pada Tahap Processing

Kelas	Train	Validasi	Test	Total
Bakteri	882	284	118	1284
Bercak Coklat	1120	320	160	1600
Bloss	1120	320	160	1600
Sehat	1120	320	160	1600

Tungro	944	243	121	1308
--------	-----	-----	-----	------

Setelah proses pembagian dataset selesai dilakukan, tahap selanjutnya adalah penerapan *data augmentation* pada data pelatihan guna meningkatkan keberagaman citra. Teknik augmentasi yang digunakan meliputi rotasi dengan sudut terbatas, pembesaran (*zoom*), pergeseran posisi citra, serta pembalikan secara horizontal. Penerapan augmentasi ini bertujuan untuk meningkatkan ketahanan model terhadap variasi sudut pengambilan gambar, perbedaan pencahayaan, serta variasi bentuk gejala penyakit yang muncul pada daun padi.

Seluruh citra kemudian disesuaikan dengan format masukan arsitektur *MobileNetV2* melalui proses pengubahan ukuran menjadi 224×224 piksel dan normalisasi nilai piksel ke dalam rentang 0–1. Proses normalisasi dilakukan untuk mempercepat proses konvergensi model serta menjaga kestabilan selama tahap pelatihan.

Proses klasifikasi citra dilakukan dengan memanfaatkan arsitektur *MobileNetV2* menggunakan pendekatan *transfer learning*. Lapisan dasar *MobileNetV2* yang telah dilatih pada dataset *ImageNet* digunakan sebagai ekstraktor fitur awal, sementara beberapa lapisan terakhir disesuaikan melalui proses *fine-tuning* agar model mampu mengenali karakteristik visual spesifik dari penyakit daun padi. Struktur *MobileNetV2* yang tersusun atas blok *inverted residual* dengan *depthwise convolution* memungkinkan model tetap ringan secara komputasi namun tetap memiliki tingkat akurasi yang baik.

Pada bagian akhir jaringan, ditambahkan beberapa lapisan pendukung yang terdiri dari *Global Average Pooling*, *Batch Normalization*, dua lapisan *Dense* dengan masing-masing 256 dan 128 neuron yang menggunakan fungsi aktivasi *ReLU*, serta lapisan *Dropout* untuk mengurangi risiko *overfitting*. Lapisan keluaran menggunakan fungsi aktivasi *softmax* dengan lima neuron yang disesuaikan dengan jumlah kelas penyakit daun padi yang diklasifikasikan.

Proses pelatihan model dioptimalkan menggunakan *optimizer Adam* dengan pengaturan *learning rate* adaptif. Selain itu, digunakan *callback ModelCheckpoint* untuk menyimpan model dengan performa terbaik berdasarkan nilai *validation accuracy*, serta *EarlyStopping* untuk menghentikan proses

pelatihan ketika nilai *validation loss* tidak menunjukkan peningkatan dalam beberapa epoch berturut-turut. Jumlah maksimum epoch ditetapkan sebanyak 100, namun pelatihan dapat dihentikan lebih awal apabila performa model telah mencapai kondisi stabil.

Tahap *processing* ini menghasilkan model klasifikasi yang mampu mengenali pola visual dari masing-masing kelas penyakit daun padi secara efektif dan menjadi dasar untuk tahap evaluasi selanjutnya.

4.3. Tahap Uji Coba dan Validasi

Tahap uji coba dan validasi dilakukan untuk mengevaluasi kinerja model klasifikasi penyakit daun padi berbasis arsitektur *MobileNetV2* yang telah dilatih. Evaluasi dilakukan menggunakan *testing set* yang tidak dilibatkan dalam proses *training*, sehingga hasil yang diperoleh mencerminkan kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Hasil evaluasi disajikan dalam berbagai bentuk visualisasi, meliputi grafik akurasi, grafik *loss*, *confusion matrix*, *classification report*, serta visualisasi hasil prediksi citra. Penyajian ini bertujuan untuk memberikan gambaran performa model secara kuantitatif maupun kualitatif.

4.3.1 Analisis Akurasi dan Loss

Gambar 4.3.1 menampilkan grafik *training accuracy* dan *validation accuracy* selama proses pelatihan model. Grafik tersebut menunjukkan bahwa nilai akurasi mengalami peningkatan yang signifikan pada epoch awal, kemudian cenderung stabil pada epoch selanjutnya. Model mencapai nilai *training accuracy* sebesar 94,6%, sementara *validation accuracy* mencapai 87,42%. Pengujian menggunakan data uji menghasilkan nilai *test accuracy* sebesar 93,46%. Pola ini mengindikasikan bahwa model mampu mempelajari fitur penyakit daun padi dengan baik tanpa menunjukkan gejala *overfitting* yang berlebihan.

Selanjutnya, Gambar 4.3.1.1 menyajikan grafik *training loss* dan *validation loss*. Nilai *training loss* menurun hingga mencapai 0,1406, sedangkan *validation loss* berada pada nilai 0,3365. Penurunan nilai *loss* yang konsisten serta selisih yang relatif kecil antara *training loss* dan *validation loss* menunjukkan bahwa

model memiliki kemampuan generalisasi yang baik terhadap data validasi.



Gambar 4.3.1. Grafik Training Accuracy dan Validation Accuracy




Gambar 4.3.1.1. Grafik Training Loss dan Validation Loss

4.3.2 Analisis Confusion Matrix

Evaluasi performa model secara lebih mendalam dilakukan dengan menggunakan *confusion matrix* yang ditampilkan pada Gambar 4.3.2. *Confusion matrix* merupakan metode evaluasi yang menyajikan perbandingan antara label sebenarnya dengan hasil prediksi model, sehingga dapat diketahui jumlah prediksi yang benar maupun kesalahan klasifikasi pada setiap kelas. Informasi yang diperoleh dari *confusion matrix* selanjutnya digunakan sebagai dasar perhitungan metrik evaluasi, seperti *precision*, *recall*, dan *f1-score* [15].

Pada penelitian ini, *confusion matrix* menggambarkan kinerja model dalam mengklasifikasikan lima kelas kondisi daun padi, yaitu penyakit bakteri, bercak coklat, blas, tungro, serta daun padi sehat. Berdasarkan hasil evaluasi, kelas bakteri dan tungro berhasil diklasifikasikan secara sempurna, yang ditunjukkan dengan seluruh citra pada kedua kelas tersebut terprediksi dengan benar. Kelas daun padi sehat juga menunjukkan performa yang sangat baik, dengan sebagian besar citra berhasil dikenali secara tepat.

Sebaliknya, tingkat kesalahan klasifikasi paling banyak ditemukan pada kelas blas dan bercak coklat, di mana sejumlah citra pada kedua kelas tersebut saling tertukar. Hal ini disebabkan oleh adanya kemiripan karakteristik visual antara kedua penyakit, khususnya pada perubahan warna daun serta pola dan tekstur bercak yang hampir serupa, sehingga menyulitkan model dalam membedakan kedua kelas secara konsisten.



Gambar 4.3.2. Confusion Matrix Model MobileNetV2

Untuk mengevaluasi kinerja model pada masing-masing kelas secara lebih spesifik, digunakan *classification report* yang menyajikan metrik *precision*, *recall*, dan *f1-score*. Hasil evaluasi tersebut ditampilkan pada Tabel 4.3.3 dan digunakan untuk menggambarkan performa klasifikasi pada setiap kelas penyakit daun padi.

4.3.3 Analisis Classification Report

Untuk menilai performa model pada masing-masing kelas secara lebih terperinci, digunakan *classification report* yang menyajikan nilai *precision*, *recall*, dan *f1-score*, sebagaimana ditampilkan pada Tabel 4.3.3.

Tabel 4.3.3. Classification Report Model MobileNetV2

Kelas	Precision	Recall	F1-Score
Bakteri	1.00	1.00	1.00
Bercak Coklat	0.94	0.92	0.93
Blas	0.92	0.83	0.88
Sehat	1.00	1.00	1.00

Tungro	0.85	0.96	0.90
Accuracy	0.93%		

Berdasarkan hasil tersebut, kelas bakteri dan tungro menunjukkan kinerja terbaik dengan nilai *precision*, *recall*, dan *f1-score* masing-masing sebesar 1,00. Sementara itu, kelas blas memiliki nilai *recall* terendah dibandingkan kelas lainnya, yang mengindikasikan bahwa masih terdapat sebagian citra blas yang salah diklasifikasikan ke dalam kelas lain. Meskipun demikian, nilai akurasi keseluruhan menunjukkan bahwa model memiliki kinerja klasifikasi yang baik dan stabil dalam mengenali berbagai jenis penyakit daun padi.

4.3.4 Visualisasi Hasil Prediksi

Sebagai pelengkap evaluasi kuantitatif, dilakukan visualisasi hasil prediksi model terhadap beberapa citra uji yang dipilih secara acak, sebagaimana ditunjukkan pada Gambar 4.3.4. Visualisasi ini memperlihatkan bahwa model mampu memberikan prediksi yang sesuai dengan label sebenarnya pada sebagian besar citra yang diuji.

Kesalahan prediksi yang terjadi umumnya disebabkan oleh kondisi citra dengan pencahayaan yang tidak merata atau gejala penyakit yang belum tampak secara jelas. Kendati demikian, hasil visualisasi secara keseluruhan menunjukkan bahwa model telah mampu mengenali pola visual utama yang menjadi ciri khas dari masing-masing kelas penyakit daun padi.



Gambar 4.3.4. Hasil Prediksi Citra Menggunakan Model MobileNetV2

4.4. Pembahasan

Berdasarkan hasil uji coba dan evaluasi yang telah dilakukan, dapat disimpulkan bahwa model *MobileNetV2* yang dikombinasikan dengan pendekatan *transfer learning* mampu

melakukan klasifikasi penyakit daun padi secara efektif. Penerapan tahapan *pre-processing*, *data augmentation*, serta strategi *fine-tuning* pada lapisan akhir jaringan memberikan kontribusi yang signifikan terhadap pencapaian tingkat akurasi yang tinggi.

Meskipun masih ditemukan kesalahan klasifikasi pada kelas-kelas penyakit yang memiliki kemiripan karakteristik visual, kinerja keseluruhan model menunjukkan bahwa arsitektur *MobileNetV2* layak digunakan sebagai dasar dalam pengembangan sistem pendeteksi penyakit tanaman padi berbasis citra. Dengan efisiensi komputasi dan performa yang kompetitif, model ini memiliki potensi untuk diterapkan pada sistem pendukung keputusan di bidang pertanian.

5. KESIMPULAN

Penelitian ini berhasil merancang dan mengimplementasikan sistem klasifikasi penyakit daun padi berbasis citra digital dengan memanfaatkan metode *deep learning* menggunakan arsitektur *MobileNetV2* serta pendekatan *transfer learning*. Model yang dikembangkan mampu mengklasifikasikan lima kondisi daun padi, yaitu penyakit bakteri, bercak coklat, blas, tungro, dan daun sehat, dengan tingkat performa yang konsisten dan stabil. Penerapan tahapan *pre-processing* serta strategi *fine-tuning* pada lapisan akhir jaringan terbukti mampu meningkatkan efektivitas proses pembelajaran model dan menghasilkan nilai akurasi pengujian yang tinggi.

Hasil evaluasi berdasarkan metrik akurasi, *loss*, *confusion matrix*, dan *classification report* menunjukkan bahwa sebagian besar kelas penyakit dapat dikenali dengan baik oleh model, meskipun masih ditemukan kesalahan klasifikasi pada kelas-kelas yang memiliki kemiripan karakteristik visual. Secara keseluruhan, arsitektur *MobileNetV2* dinilai layak digunakan sebagai solusi klasifikasi penyakit daun padi yang efisien dan akurat. Untuk pengembangan selanjutnya, penelitian dapat diarahkan pada penambahan jumlah dan variasi dataset, serta eksplorasi penggunaan arsitektur *deep learning* lainnya guna meningkatkan kinerja dan kemampuan generalisasi sistem.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan dan kontribusi dalam pelaksanaan penelitian ini, baik secara langsung maupun tidak langsung, sehingga penelitian ini dapat diselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] E. Anggiratih, S. Siswanti, S. K. Octaviani, and A. Sari, "Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning," *J. Ilm. SINUS*, vol. 19, no. 1, pp. 75–83, 2021, doi: 10.30646/sinus.v19i1.526.
- [2] A. Julianto, A. Sunyoto, and F. W. Wibowo, "Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi," *Tek. Teknol. Inf. dan Multimed.*, vol. 3, no. 2, pp. 98–105, 2022, [Online]. Available: <https://doi.org/10.46764/teknimedia.v3i2.77>
- [3] F. H. Hawari, F. Fadillah, M. R. Alviandi, and T. Arifin, "KLASIFIKASI PENYAKIT PADI MENGGUNAKAN ALGORITMA CNN (CONVOLUTIONAL NEURAL NETWORK)," *J. RESPONSIF*, vol. 4, no. 2, pp. 184–189, 2022.
- [4] S. Agustiani, Y. T. Arifin, A. Junaidi, S. K. Wildah, and A. Mustopa, "Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram," *J. Komputasi*, vol. 10, no. 1, pp. 65–74, 2022, doi: 10.23960/komputasi.v10i1.2961.
- [5] U. N. Oktaviana, R. Hendrawan, A. F. K. Annas, and G. W. Wicaksono, "Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 6, pp. 1216–1222, 2021.
- [6] N. B. Pamungkas and A. Suhendar, "Penerapan Metode Convolutional Neural Network pada Sistem Klasifikasi Penyakit Tanaman Apel berdasarkan Citra Daun," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 2, pp. 675–684, 2024, doi: 10.29408/edumatic.v8i2.27958.
- [7] A. C. Milano, A. Yasid, and R. T. Wahyuningrum, "Klasifikasi Penyakit Daun Padi Menggunakan Model Deep Learning Efficientnet-B6," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, pp. 551–559, 2024, doi: 10.23960/jitet.v12i1.3855.
- [8] H. J. Choi and J. Y. Lee, "Comparative study between healthy young and elderly subjects: Higher-order statistical parameters as indices of vocal aging and sex," *Appl. Sci.*, vol. 11, no.

- 15, pp. 2–14, 2021, doi: 10.3390/app11156966.
- [9] P. Robicheaux *et al.*, “Roboflow100-VL: A Multi-Domain Object Detection Benchmark for Vision-Language Models,” no. NeurIPS, pp. 1–32, 2025, [Online]. Available: <http://arxiv.org/abs/2505.20612>
- [10] H. Moayyed, M. Mohammadpourfard, C. Konstantinou, A. Moradzadeh, B. Mohammadi-Ivatloo, and A. P. Aguiar, “Image Processing Based Approach for False Data Injection Attacks Detection in Power Systems,” *IEEE Access*, vol. 10, pp. 12412–12420, 2022, doi: 10.1109/ACCESS.2021.3131506.
- [11] C. Shorten and T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 1, p. 48, 2019, doi: 10.1186/s40537-019-0197-0.
- [12] N. F. Armin, N. Hidayat, and A. A. Soebroto, “Implementasi Metode Analytical Hierarchy Process (AHP) – Weighted Product (WP) dalam Sistem Pendukung Keputusan untuk Rekomendasi Pelanggan Terbaik berbasis Website (Studi Kasus: PT. Pelabuhan Indonesia IV (Persero) Makassar),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 6, pp. 2949–2959, 2022, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/11245>
- [13] H. Y. Irwanto *et al.*, “Development Steps of Avionics and Flight Control System of Flight Vehicle,” *J. RESTI*, vol. 7, no. 4, pp. 791–796, 2023, doi: 10.29207/resti.v7i4.4953.
- [14] N. H. Muttaqin and A. M. Widodo, “Evaluation of Transfer Learning-Based Convolutional Neural Networks (InceptionV3 and MobileNetV2) for Facial Skin-Type Classification,” *J. Ilmu Komput. dan Inform.*, vol. 5, no. 1, pp. 11–32, 2025, doi: 10.54082/jiki.264.
- [15] I. F. Hawari *et al.*, “Pengaruh Teknik Oversampling Pada Algoritma Machine Learning Dalam Klasifikasi Body Mass Index (BMI),” *J. Ris. dan Apl. Mat.*, vol. 08, no. 01, pp. 51–68, 2024.