



Implementasi Transfer Learning dengan Arsitektur MobileNetV2 untuk Klasifikasi Penyakit pada Daun Padi

Alek Wijaya ¹, Andre Satriawan ^{2*}, M. Soekarno Putra ³, dan Muhammad Nasir ⁴

¹ Universitas Bina Darma; Palembang, Sumatera Selatan; e-mail : andresatriawan19@binadarma.ac.id

² Universitas Bina Darma; Palembang, Sumatera Selatan; e-mail : alex_wj@gmail.com

³ Universitas Bina Darma; Palembang, Sumatera Selatan; e-mail : soekarno@binadarma.ac.id

⁴ Universitas Bina Darma; Palembang, Sumatera Selatan; e-mail : nasir@binadarma.ac.id

* Corresponding Author : Andre Satriawan

Abstract: Rice is a strategic commodity in Indonesia, yet its productivity is often threatened by leaf diseases such as Bacterial Leaf Blight, Brown Spot, Narrow Brown Spot, and Tungro. Conventional identification conducted by farmers is subjective and may delay proper treatment. This study implements transfer learning using the MobileNetV2 architecture for rice leaf disease classification. The dataset was collected directly from rice fields in OKU Timur, South Sumatra, consisting of five classes (Bacterial Leaf Blight, Brown Spot, Healthy, Narrow Brown Spot, and Tungro), each containing 300 images except Narrow Brown Spot, which was balanced through light augmentation. All images underwent cropping, resizing to 224×224 pixels, and normalization before being split into training, validation, and testing sets. The proposed model achieved 99.11% validation accuracy and 100% testing accuracy, with near-perfect precision, recall, and f1-score. The model was then deployed into a user-friendly web application using Streamlit, enabling farmers to upload rice leaf images for instant classification and recommended treatments. These findings demonstrate that MobileNetV2 with transfer learning provides accurate early detection of rice leaf diseases and supports better decision-making in rice cultivation.

Keywords: Transfer Learning; MobileNetV2; Rice Leaf Disease; Classification, Streamlit.

Abstrak: Padi merupakan komoditas strategis di Indonesia, namun produktivitasnya sering terganggu oleh penyakit daun seperti Hawar Daun Bakteri (Bacterial Leaf Blight), Bercak Coklat (Brown Spot), Bercak Coklat Sempit (Narrow Brown Spot), dan Tungro. Identifikasi konvensional yang dilakukan petani bersifat subjektif dan berpotensi menunda penanganan yang tepat. Penelitian ini mengimplementasikan transfer learning menggunakan arsitektur MobileNetV2 untuk klasifikasi penyakit daun padi. Dataset dikumpulkan langsung dari lahan pertanian di OKU Timur, Sumatera Selatan, terdiri dari lima kelas (Bacterial Leaf Blight, Brown Spot, Healthy, Narrow Brown Spot, dan Tungro), masing-masing 300 citra kecuali Narrow Brown Spot yang disimbangkan melalui augmentasi ringan. Seluruh citra melalui tahap pemotongan (cropping), pengubahan ukuran (resize) menjadi 224×224 piksel, serta normalisasi sebelum dibagi menjadi data latih, validasi, dan uji. Model mencapai akurasi validasi 99,11% dan akurasi uji 100% dengan nilai precision, recall, dan f1-score yang mendekati sempurna. Model kemudian diterapkan pada aplikasi web berbasis Streamlit yang memudahkan petani mengunggah citra daun untuk mendapatkan klasifikasi dan rekomendasi penanganan secara instan. Hasil ini menunjukkan bahwa MobileNetV2 dengan transfer learning efektif untuk deteksi dini penyakit daun padi dan dapat mendukung pengambilan keputusan dalam budidaya padi.

Kata kunci: Transfer Learning; MobileNetV2; Penyakit Daun Padi; Klasifikasi; Streamlit

Received: September 16, 2025

Revised: September 24, 2025

Accepted: November 26, 2025

Published: November 29, 2025

Curr. Ver.: November 29, 2025



Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY SA) license (<https://creativecommons.org/licenses/by-sa/4.0/>)

1. Pendahuluan

Padi merupakan komoditas strategis sekaligus makanan pokok mayoritas penduduk Indonesia, dengan konsumsi beras per kapita pada 2016 mencapai 139 kg sehingga perlu impor 24.929 ton; sebagai usaha tani, padi berperan penting dalam pertumbuhan pertanian, pengentasan pengangguran dan kemiskinan, serta menjaga ketahanan dan kemandirian pangan [1]. Namun, serangan penyakit pada daun padi seperti Bacterial Leaf Blight, Brown Spot, Narrow Brown Spot, dan Tungro dapat mengurangi hasil panen secara signifikan. Serangan penyakit tersebut menjadi salah satu faktor utama penurunan produktivitas padi di Indonesia [2]. Metode identifikasi penyakit secara manual yang dilakukan petani umumnya memerlukan pengalaman serta pengetahuan mendalam, sehingga tidak semua petani mampu mengenali penyakit dengan tepat. Hal ini menyebabkan keterlambatan dalam penanganan penyakit yang bisa mengakibatkan penurunan hasil produksi padi [3].

Perkembangan teknologi deep learning, khususnya *transfer learning*, telah banyak digunakan dalam bidang pertanian untuk identifikasi penyakit tanaman. *Transfer Learning* memungkinkan penggunaan kembali bobot model yang telah dilatih pada dataset besar seperti ImageNet, sehingga proses pelatihan pada dataset baru menjadi lebih cepat dan efisien [4]. Salah satu arsitektur yang efisien adalah MobileNetV2, karena memiliki ukuran model yang ringan namun tetap mampu menghasilkan akurasi tinggi [5]. Dalam penelitian ini, penulis mengimplementasikan *transfer learning* dengan MobileNetV2 untuk mengklasifikasikan penyakit daun padi [6]. Dataset dikumpulkan secara langsung dari lapangan melalui kelompok tani HUMA KANDIS di Kabupaten OKU Timur, kemudian diproses dan diseimbangkan dengan teknik augmentasi untuk memperbanyak data dari dataset asli yang berguna untuk meningkatkan akurasi dan menghindari overfitting pada model yang dibangun [7]. Solusi yang ditawarkan dari penelitian ini adalah menghadirkan sebuah model klasifikasi berbasis deep learning yang mampu membantu petani dalam mendeteksi penyakit daun padi secara lebih cepat, akurat, dan efisien, sehingga diharapkan dapat mendukung pengambilan keputusan dalam pengendalian hama serta meningkatkan produktivitas pertanian.

2. Kajian Pustaka atau Penelitian Terkait

Penelitian terkait deteksi penyakit tanaman padi berbasis teknologi kecerdasan buatan telah banyak dilakukan di Indonesia. Seperti yang dilakukan oleh Rachman et al. [8] mengembangkan sistem informasi deteksi penyakit pada tanaman padi dengan metode Convolutional Neural Network (CNN) untuk mengenali penyakit Brown Spot, Hispa, dan Leaf Blast. Sistem ini mampu memberikan hasil klasifikasi yang cukup akurat dan dapat membantu petani dalam mengidentifikasi jenis penyakit secara lebih cepat dibandingkan metode manual. Penelitian tersebut menegaskan bahwa CNN memiliki potensi besar untuk diterapkan dalam bidang pertanian digital, khususnya dalam mendukung efisiensi pengendalian penyakit tanaman.

Selanjutnya, Hidayat et al. [9] melakukan penelitian dengan memanfaatkan arsitektur VGG-16 berbasis transfer learning yang dipadukan dengan teknik segmentasi K-Means untuk analisis penyakit pada daun padi. Hasil yang diperoleh menunjukkan peningkatan akurasi identifikasi penyakit karena metode ini tidak hanya melakukan klasifikasi, tetapi juga mengoptimalkan proses segmentasi citra daun. Dengan pendekatan ini, sistem mampu lebih efektif dalam mengekstraksi fitur penting dari citra, sehingga akurasi klasifikasi menjadi lebih tinggi.

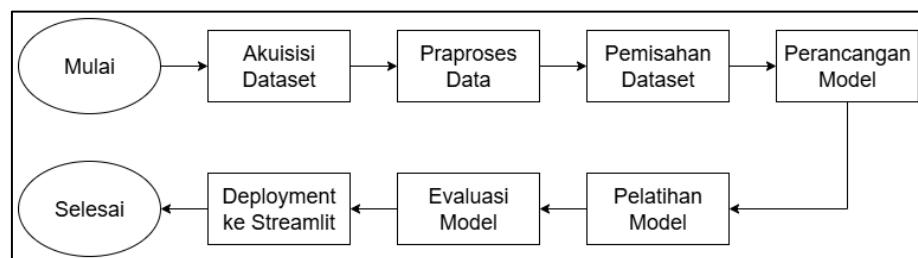
Selain itu, Annur et al. [10] memanfaatkan arsitektur MobileNetV2 untuk mengklasifikasi tingkat keparahan penyakit Leaf Blast pada tanaman padi. MobileNetV2 dipilih karena ringan dan efisien dalam komputasi, sehingga lebih mudah diimplementasikan pada perangkat dengan keterbatasan sumber daya. Hasil penelitian menunjukkan bahwa MobileNetV2 dapat menghasilkan kinerja yang baik dengan akurasi tinggi, sekaligus membuktikan efektivitas transfer learning untuk mendeteksi penyakit tanaman secara cepat dan tepat.

Pada tingkat internasional, Ning et al. [11] mengembangkan model Convolutional Neural Network untuk mengenali penyakit daun padi pada kondisi lapangan yang tidak homogen. Penelitian tersebut menegaskan bahwa keberagaman dataset memengaruhi performa generalisasi model serta menyoroti pentingnya pembangunan dataset multisumber untuk meningkatkan robustness sistem deteksi penyakit tanaman.

Latif et al. [12] kemudian mengusulkan pengembangan MobileNetV2 yang dilengkapi mekanisme attention untuk deteksi penyakit tanaman. Hasil penelitian menunjukkan peningkatan akurasi secara signifikan dibandingkan MobileNetV2 standar, sekaligus menegaskan bahwa arsitektur ringan masih dapat ditingkatkan melalui integrasi modul modern seperti attention mechanism. Berdasarkan penelitian-penelitian tersebut, dapat disimpulkan bahwa penggunaan metode deep learning dengan pendekatan transfer learning sangat relevan untuk dikembangkan lebih lanjut. Arsitektur seperti CNN, VGG-16, dan MobileNetV2 terbukti mampu memberikan akurasi yang tinggi dalam klasifikasi penyakit padi, serta berpotensi menjadi solusi praktis dalam membantu petani mengidentifikasi penyakit sejak dini.

3. Metode yang Diusulkan

Tahapan dalam penggunaan MobileNetV2 dalam klasifikasi, mencakup Akuisisi Dataset, Praproses Data, Pemisahan Dataset, Perancangan Model, Pelatihan Model, dan Evaluasi Model [13]. Metode penelitian yang digunakan dalam penelitian ini adalah metode eksperimen dengan pendekatan kuantitatif. Penelitian ini menambahkan satu tahap akhir berupa penerapan model ke dalam aplikasi berbasis Streamlit dalam bentuk website, yang bertujuan untuk menjembatani hasil klasifikasi dengan pengguna akhir secara praktis melalui antarmuka interaktif berbasis web [14].



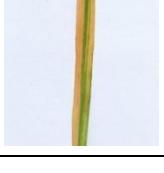
Gambar 1. Alur Penelitian

3.1 Akuisisi Dataset

Proses pengambilan data dilakukan di lahan pertanian Kelompok Tani HUMA KANDIS, Desa Surabaya, Kecamatan Madang Suku III, OKU Timur, Sumatera Selatan, pada 5 Juni–2 Juli 2025 dengan dokumentasi citra daun padi menggunakan kamera ponsel TECNO POVA 6 Pro 5G secara tegak lurus (top view) di atas kertas putih polos, dilengkapi wawancara dengan lima petani yang mengidentifikasi empat penyakit utama—Bacterial Leaf Blight ditandai bercak abu-abu tidak beraturan yang meluas dan mengering dengan eksudat bakteri [15]. Brown Spot dengan bercak elips/berlian berwarna coklat hingga keputihan bergantung kondisi lingkungan [16]. Healthy dengan daun hijau tanpa bercak atau kerusakan [17]. Narrow Brown Spot berupa bercak sempit memanjang sejajar tulang daun yang meluas ke pelepas, batang, atau bunga [18]. serta Tungro dengan gejala daun menguning-oranye, menggulung, anakan berkurang, tanaman kerdil dan terhambat [19]. dengan jumlah data yang terkumpul yaitu 300 gambar Bacterial Leaf Blight, 300 gambar Brown Spot, 300 gambar Healthy, 147 gambar Narrow Brown Spot, dan 300 gambar Tungro. Tabel 1. Kelas, Jumlah Gambar, dan Contoh Gambar Setiap Kelas.

Tabel 1. Kelas, jumlah data, dan contoh gambar setiap daun padi

Kelas	Jumlah Gambar	Contoh Gambar
Bacterial Leaf Blight	300	

Brown Spot	300	
Healthy	300	
Narrow Brown Spot	147	
Tungro	300	

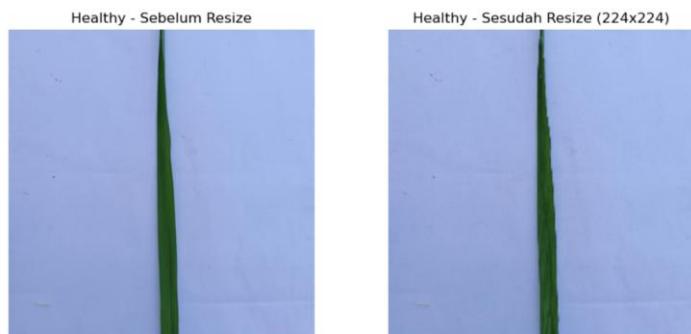
3.2 Praproses Data

Sebelum dataset digunakan dalam tahap pelatihan model, diperlukan proses praproses data (preprocessing) untuk memastikan kualitas citra seragam dan siap diproses oleh arsitektur MobileNetV2. Tahapan ini bertujuan menghilangkan elemen yang tidak relevan, menyeragamkan ukuran gambar, serta menyeimbangkan jumlah data antar kelas sehingga model dapat belajar secara optimal. Langkah pertama dalam preprocessing adalah pemotongan (cropping) gambar secara manual. Setelah gambar diambil dari lapangan, sebagian besar citra masih mengandung elemen-elemen non-daun seperti latar belakang yang terlalu lebar, tangan peneliti, tanaman lainnya yang berbeda jenis, atau bayangan yang tidak diinginkan. Oleh karena itu, setiap gambar dipotong secara manual menggunakan perangkat lunak pengedit gambar aplikasi bawaan di laptop untuk menyisakan hanya bagian daun padi yang menjadi objek utama.



Gambar 2. Gambar sebelum dan sesudah cropping manual

Setelah dilakukan cropping, seluruh gambar diseragamkan ukurannya menjadi 224 x 224 piksel. Ukuran ini dipilih karena merupakan ukuran standar input pada arsitektur MobileNetV2 yang telah dirancang untuk menerima citra beresolusi 224x224 piksel. Proses resizing ini dilakukan menggunakan pustaka Python seperti OpenCV atau Keras ImageDataGenerator yang secara otomatis dapat menyesuaikan dimensi citra.



Gambar 3. Gambar sebelum dan sesudah resize

Selanjutnya adalah augmentasi data kelas yang memiliki jumlah sedikit. Augmentasi data merupakan proses memperkaya dataset dengan menciptakan variasi baru dari data asli untuk meningkatkan performa model pembelajaran mesin, terutama pada dataset dengan keterbatasan jumlah data pelatihan [20]. Dalam penelitian ini, augmentasi data dilakukan secara khusus hanya pada kelas Narrow Brown Spot, yang semula hanya memiliki 147 gambar, jumlah yang jauh lebih sedikit dibandingkan kelas lainnya (masing-masing 300 gambar). Ketidakseimbangan ini dapat menyebabkan model lebih cenderung mengenali kelas dengan data terbanyak (bias kelas dominan), sehingga perlu diseimbangkan agar hasil klasifikasi menjadi adil dan akurat. Setelah melalui tahap preprocessing dan augmentasi data, dataset akhir yang digunakan untuk pelatihan model klasifikasi konsisten menjadi 300 gambar setiap kelas.



Gambar 4. Augmentasi data kelas narrow brown spot

3.3 Pemisahan Dataset

Setelah seluruh gambar daun padi berhasil dikumpulkan, melalui tahap preprocessing, serta dilakukan augmentasi data untuk menyamakan jumlah gambar pada setiap kelas, maka langkah berikutnya adalah pembagian dataset. Proses ini bertujuan untuk memisahkan data yang digunakan dalam pelatihan, validasi, dan pengujian model agar hasil yang diperoleh lebih objektif dan terukur. Dataset dibagi ke dalam tiga subset, yaitu training set sebesar 70% yang digunakan untuk melatih model, validation set sebesar 15% yang berfungsi untuk mengevaluasi kinerja model selama proses pelatihan dan mencegah overfitting, serta testing set sebesar 15% yang digunakan untuk menguji performa akhir model pada data yang belum pernah dilihat sebelumnya [21]. Proses pembagian dataset tidak dilakukan secara manual, melainkan diatur langsung melalui kode program. Dengan cara ini, pembagian data menjadi lebih konsisten, sistematis, dan sesuai dengan kebutuhan eksperimen yang dilakukan.

3.4 Perancangan Model

Kemudian pada tahap perancangan model klasifikasi penyakit daun padi dengan pendekatan transfer learning menggunakan arsitektur MobileNetV2. Arsitektur ini dipilih karena efisien, memiliki jumlah parameter relatif kecil, dan mampu memberikan kinerja optimal tanpa membutuhkan komputasi yang besar. MobileNetV2 memanfaatkan depthwise separable convolution serta inverted residuals dengan linear bottleneck sehingga proses ekstraksi fitur dapat

berjalan cepat namun tetap mempertahankan kualitas representasi citra. Dalam penelitian ini, MobileNetV2 digunakan sebagai feature extractor dengan bobot awal dari ImageNet. Lapisan akhir kemudian dimodifikasi agar sesuai dengan lima kelas pada dataset daun padi, yaitu Bacterial Leaf Blight, Brown Spot, Healthy, Narrow Brown Spot, dan Tungro. Desain model meliputi input layer berukuran 224×224 piksel, MobileNetV2 sebagai ekstraktor fitur utama, global average pooling untuk mereduksi dimensi, dense layer dengan aktivasi ReLU untuk mengolah hasil ekstraksi, serta output layer dengan aktivasi Softmax yang menghasilkan probabilitas klasifikasi setiap kelas. Untuk mencegah overfitting dan mengoptimalkan pelatihan, rancangan model juga dilengkapi dengan teknik regulasi berupa Early Stopping dan ReduceLROnPlateau. Dengan rancangan ini, model diharapkan mampu mengenali pola pada daun padi secara akurat dan memberikan hasil klasifikasi yang andal.

4. Hasil dan Pembahasan

4.1 Pelatihan Model

Proses pelatihan model menggunakan arsitektur MobileNetV2 menunjukkan peningkatan performa yang sangat signifikan dan konsisten dari awal hingga akhir pelatihan. Model dilatih selama 20 epoch dengan data yang telah dibagi ke dalam set pelatihan dan validasi. Hasil dari setiap epoch menunjukkan pola pembelajaran yang stabil dan konvergen, baik dari sisi training accuracy/loss maupun validation accuracy/loss. Secara keseluruhan, hasil pelatihan menunjukkan bahwa strategi *transfer learning* dengan arsitektur MobileNetV2 sangat efektif dalam klasifikasi penyakit daun padi. Model berhasil belajar dengan cepat dan efisien, serta mampu mencapai hasil validasi yang sangat tinggi, yaitu Akurasi Validasi Akhir 99,11%, Loss Validasi Akhir 0.0218, Akurasi Pelatihan Akhir: 99,97%, dan Loss Pelatihan Akhir: 0.0139.

Epoch 1/20	
33/33	141s 4s/step - accuracy: 0.6106 - loss: 0.9873 - val_accuracy: 0.9689 - val_loss: 0.2011
Epoch 2/20	
33/33	110s 3s/step - accuracy: 0.9500 - loss: 0.2219 - val_accuracy: 0.9822 - val_loss: 0.1053
Epoch 3/20	
33/33	104s 3s/step - accuracy: 0.9739 - loss: 0.1154 - val_accuracy: 0.9778 - val_loss: 0.0817
Epoch 4/20	
33/33	228s 7s/step - accuracy: 0.9838 - loss: 0.0817 - val_accuracy: 0.9822 - val_loss: 0.0630
Epoch 5/20	
33/33	233s 7s/step - accuracy: 0.9897 - loss: 0.0664 - val_accuracy: 0.9867 - val_loss: 0.0548
Epoch 6/20	
33/33	231s 7s/step - accuracy: 0.9882 - loss: 0.0601 - val_accuracy: 0.9867 - val_loss: 0.0477
Epoch 7/20	
33/33	229s 7s/step - accuracy: 0.9919 - loss: 0.0485 - val_accuracy: 0.9911 - val_loss: 0.0410
Epoch 8/20	
33/33	214s 6s/step - accuracy: 0.9943 - loss: 0.0396 - val_accuracy: 0.9911 - val_loss: 0.0379
Epoch 9/20	
33/33	214s 6s/step - accuracy: 0.9981 - loss: 0.0323 - val_accuracy: 0.9911 - val_loss: 0.0353
Epoch 10/20	
33/33	218s 7s/step - accuracy: 0.9951 - loss: 0.0318 - val_accuracy: 0.9911 - val_loss: 0.0331
Epoch 11/20	
33/33	218s 7s/step - accuracy: 0.9995 - loss: 0.0231 - val_accuracy: 0.9911 - val_loss: 0.0317
Epoch 12/20	
33/33	263s 7s/step - accuracy: 0.9975 - loss: 0.0235 - val_accuracy: 0.9911 - val_loss: 0.0292
Epoch 13/20	
33/33	217s 7s/step - accuracy: 0.9927 - loss: 0.0302 - val_accuracy: 0.9911 - val_loss: 0.0265
Epoch 14/20	
33/33	220s 7s/step - accuracy: 0.9995 - loss: 0.0166 - val_accuracy: 0.9911 - val_loss: 0.0262
Epoch 15/20	
33/33	218s 7s/step - accuracy: 0.9985 - loss: 0.0185 - val_accuracy: 0.9911 - val_loss: 0.0259
Epoch 16/20	
33/33	216s 7s/step - accuracy: 0.9976 - loss: 0.0163 - val_accuracy: 0.9911 - val_loss: 0.0233
Epoch 17/20	
33/33	214s 7s/step - accuracy: 1.0000 - loss: 0.0165 - val_accuracy: 0.9911 - val_loss: 0.0243
Epoch 18/20	
33/33	217s 7s/step - accuracy: 1.0000 - loss: 0.0144 - val_accuracy: 0.9911 - val_loss: 0.0223
Epoch 19/20	
33/33	284s 7s/step - accuracy: 0.9981 - loss: 0.0168 - val_accuracy: 0.9911 - val_loss: 0.0226
Epoch 20/20	
33/33	239s 7s/step - accuracy: 0.9997 - loss: 0.0139 - val_accuracy: 0.9911 - val_loss: 0.0218

Gambar 5. Hasil pelatihan model

4.2 Evaluasi Model

Untuk menilai kinerja model klasifikasi penyakit pada daun padi, digunakan beberapa metrik evaluasi yang mampu memberikan gambaran menyeluruh terhadap performa model. Evaluasi dilakukan tidak hanya dengan melihat tingkat akurasi secara keseluruhan, tetapi juga melalui analisis detail menggunakan classification report yang mencakup precision, recall, dan f1-score, serta confusion matrix yang memperlihatkan distribusi prediksi model terhadap setiap kelas. Dengan demikian, hasil evaluasi ini dapat memberikan pemahaman yang lebih mendalam mengenai kemampuan model dalam mengklasifikasikan lima kelas daun padi secara tepat. Classification report adalah sebuah metrik evaluasi yang digunakan untuk mengukur

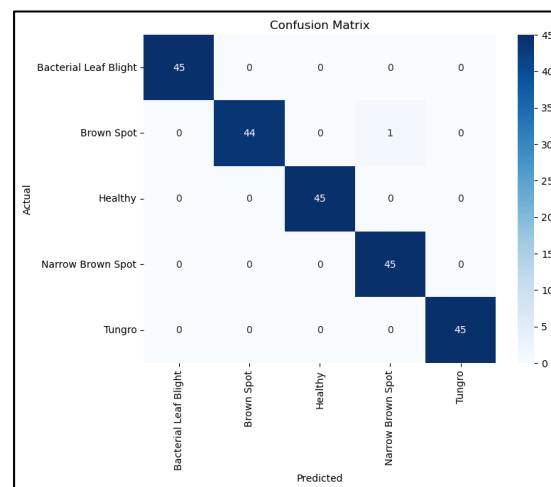
kualitas performa prediksi dari model klasifikasi. Laporan ini menampilkan beberapa indikator penting seperti precision, recall, f1-score, support, dan accuracy. Classification report membantu dalam melihat performa model secara lebih rinci dan membandingkan hasil antar kelas dalam sebuah tugas klasifikasi [22]. Berikut adalah hasil classification report dari model yang sudah di latih.

		45s	4s/step			
		precision	recall	f1-score	support	
Bacterial Leaf Blight		1.00	1.00	1.00	45	
Brown Spot		1.00	0.98	0.99	45	
Healthy		1.00	1.00	1.00	45	
Narrow Brown Spot		0.98	1.00	0.99	45	
Tungro		1.00	1.00	1.00	45	
		accuracy		1.00	225	
		macro avg	1.00	1.00	1.00	225
		weighted avg	1.00	1.00	1.00	225

Gambar 6. Classification Report

Gambar ini menampilkan ringkasan metrik evaluasi untuk setiap kelas, meliputi precision, recall, f1-score, dan support. Nilai-nilai tersebut memberikan gambaran seberapa baik model mampu mengklasifikasikan masing-masing kategori penyakit secara akurat dan konsisten. Precision adalah hasil perbandingan dari jumlah data bernilai positif dengan hasil jumlah data benar bernilai positif dan data salah bernilai positif [23]. Nilai precision yang tinggi menunjukkan bahwa model jarang memberikan prediksi positif yang salah. Dari laporan di atas, terlihat bahwa semua kelas memiliki nilai precision sebesar 1.00, kecuali kelas Narrow Brown Spot yang sedikit lebih rendah yaitu 0.98. Artinya, model hampir tidak pernah salah dalam memprediksi suatu kelas, terutama pada Bacterial Leaf Blight, Healthy, dan Tungro yang memiliki precision sempurna. Selanjutnya Recall adalah rasio antara jumlah prediksi benar positif dengan total data aktual yang positif. Recall mengukur seberapa baik model menangkap seluruh instance dari suatu kelas [24]. Dalam laporan ini, recall untuk hampir semua kelas adalah 1.00, kecuali pada kelas Brown Spot yang bernilai 0.98. Ini menunjukkan bahwa model mampu mendeteksi hampir seluruh gambar yang benar-benar termasuk dalam setiap kelas. Selanjutnya F1-score adalah rata-rata harmonis antara precision dan recall. Nilai ini sangat berguna ketika diperlukan keseimbangan antara precision dan recall, khususnya dalam konteks klasifikasi multi-kelas [25]. Dalam laporan ini, nilai f1-score untuk seluruh kelas berada pada kisaran 0.99 hingga 1.00, yang menandakan kinerja model sangat optimal dan seimbang dalam mengklasifikasikan semua kelas. Selanjutnya Accuracy adalah metrik yang mengukur sejauh mana model klasifikasi dapat mengklasifikasikan data dengan benar secara keseluruhan [26]. Secara keseluruhan, model memiliki tingkat akurasi sebesar 1.00, atau 100%, terhadap data uji yang terdiri dari 225 gambar (45 gambar untuk masing-masing dari 5 kelas). Ini menunjukkan bahwa model mampu mengklasifikasikan seluruh gambar dengan sangat baik dan hampir tanpa kesalahan. Meskipun model mencapai akurasi 100%, hasil ini perlu ditafsirkan dengan hati-hati karena ada kemungkinan overfitting. Dataset penelitian relatif homogen karena diambil di satu lokasi dengan kondisi yang seragam sehingga model mungkin belum teruji pada variasi lapangan yang lebih luas. Oleh karena itu, pengujian pada dataset dari lingkungan berbeda diperlukan untuk menilai kemampuan generalisasi model secara lebih objektif.

Selanjutnya ada Confusion Matrix digunakan untuk mengevaluasi tingkat akurasi dari suatu proses klasifikasi yang telah dilakukan. Tingkat akurasi ini mengindikasikan proporsi jumlah prediksi yang benar. Dengan menggunakan confusion matrix, kita dapat melihat secara detail kinerja suatu sistem klasifikasi dan mengidentifikasi di mana terjadi kesalahan klasifikasi. Confusion matrix merupakan sebuah teknik yang mudah dan efektif dalam mengukur kinerja sistem klasifikasi. Berikut adalah hasil confusion matrix dari model yang sudah di latih.

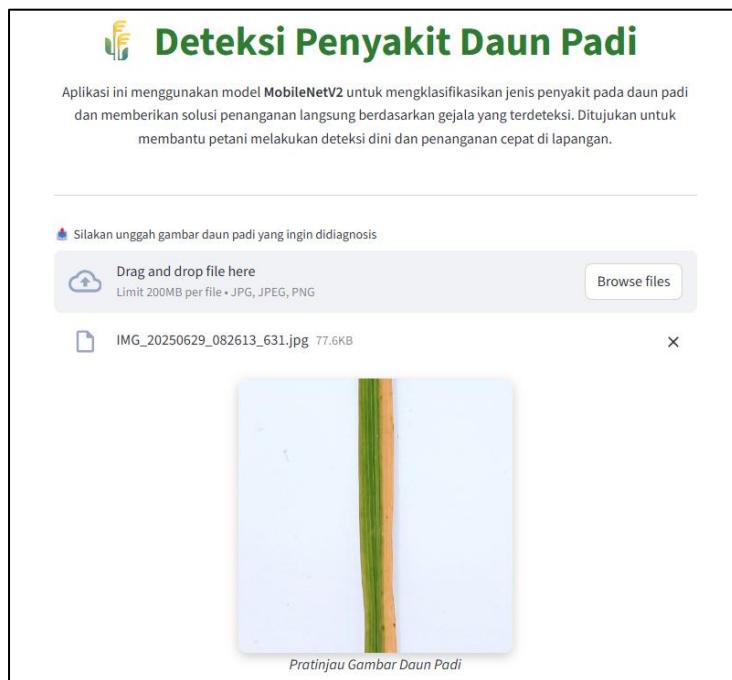


Gambar 7. Computation Matrix

Gambar ini menunjukkan distribusi prediksi model untuk setiap kelas. Nilai diagonal menggambarkan jumlah prediksi yang benar, sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi. Matriks ini memudahkan pembaca memahami pola keberhasilan dan kesalahan model dalam mendeteksi penyakit daun padi. Untuk kelas Bacterial Leaf Blight Seluruh 45 gambar diklasifikasikan dengan benar (nilai diagonal = 45), tanpa adanya kesalahan klasifikasi ke kelas lain. Ini menunjukkan kinerja sempurna pada kelas ini. Lalu kelas Brown Spot Dari 45 gambar, sebanyak 44 diklasifikasikan dengan benar, dan 1 gambar salah diklasifikasikan sebagai Narrow Brown Spot. Ini berarti model memiliki tingkat akurasi yang sangat tinggi namun tidak sempurna pada kelas ini. Hal ini mungkin disebabkan kemiripan visual antara gejala Brown Spot dan Narrow Brown Spot. Lalu kelas Healthy Semua 45 gambar berhasil diklasifikasikan dengan benar ke kelas "Healthy". Ini menandakan bahwa model sangat baik dalam mengenali daun yang sehat. Lalu kelas Narrow Brown Spot Seperti halnya kelas Healthy, seluruh 45 gambar Narrow Brown Spot juga berhasil diklasifikasikan dengan benar. Ini menunjukkan bahwa meskipun awalnya kelas ini memiliki jumlah data yang lebih sedikit dan diperbanyak dengan augmentasi, hasil klasifikasinya tetap akurat. Lalu kelas Tungro juga memperoleh hasil klasifikasi sempurna dengan 45 prediksi yang tepat.

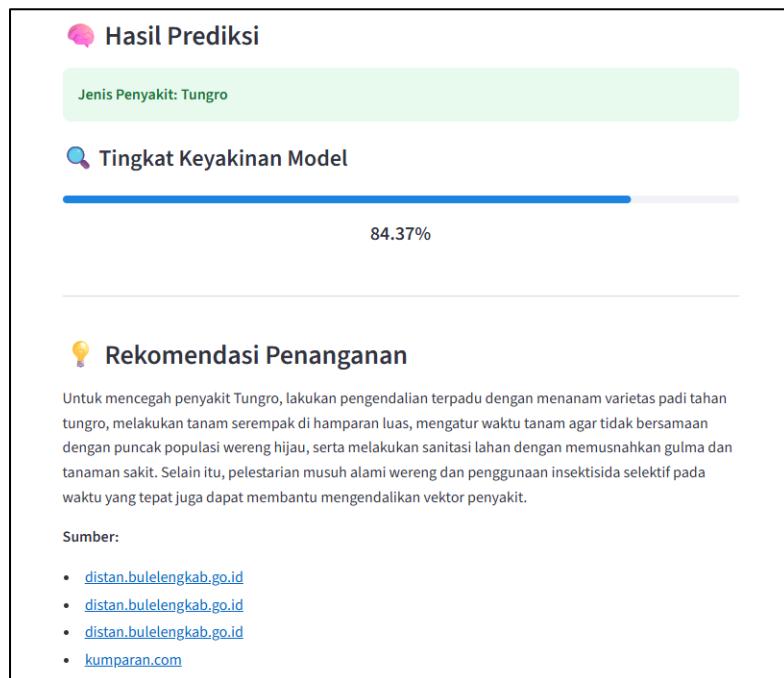
4.3 Deploymenet ke Streamlit

Setelah model berhasil dilatih dan dievaluasi, tahap selanjutnya adalah melakukan deployment agar dapat digunakan secara praktis oleh pengguna akhir. Dalam penelitian ini, model klasifikasi penyakit daun padi diimplementasikan ke dalam sebuah aplikasi berbasis Streamlit dalam bentuk website. Tujuan deployment ini adalah untuk mempermudah pengguna, khususnya petani, dalam mengidentifikasi penyakit daun padi secara cepat dan akurat hanya dengan mengunggah gambar daun. Bagian ini membahas rancangan antarmuka aplikasi serta penjelasan hasil keluaran (output) yang ditampilkan oleh sistem. Antarmuka aplikasi klasifikasi penyakit daun padi dirancang sederhana dan mudah digunakan dengan framework Streamlit. Halaman utama terdiri dari judul aplikasi, fitur unggah gambar (.jpg/.jpeg/.png), tampilan pratinjau gambar, hasil klasifikasi berupa label dan confidence score, serta saran penanganan sesuai penyakit yang terdeteksi. Desain ini memastikan aplikasi interaktif, informatif, dan ramah bagi pengguna, khususnya petani.



Gambar 9. Tampilan antarmuka aplikasi

Setelah gambar daun diunggah, sistem melakukan pra-pemrosesan (resize 224×224 piksel dan normalisasi), lalu memprediksi jenis penyakit menggunakan model MobileNetV2. Hasil prediksi ditampilkan dalam bentuk label kelas dan confidence score, disertai saran penanganan sesuai penyakit yang terdeteksi. Sebagai contoh, pada kasus penyakit Tungro dengan akurasi 98.23%, aplikasi memberikan rekomendasi pengendalian vektor, penggunaan varietas tahan, dan penanaman serempak.



Gambar 10. Contoh hasil prediksi

Dalam contoh di atas, model berhasil mengenali bahwa gambar daun yang diunggah menunjukkan gejala penyakit Tungro dengan tingkat keyakinan sebesar 98.23%. Aplikasi kemudian menyarankan langkah-langkah penanganan yang tepat sesuai dengan jenis penyakit tersebut, yaitu mengendalikan vektor penyebar (wereng hijau), menggunakan varietas padi yang tahan terhadap Tungro, serta melakukan penanaman secara serempak.

5. Kesimpulan

Penelitian ini berhasil mengimplementasikan transfer learning dengan arsitektur MobileNetV2 untuk klasifikasi penyakit daun padi. Dengan memanfaatkan dataset yang dikumpulkan langsung dari lahan pertanian serta menerapkan tahapan *preprocessing* dan augmentasi data untuk penyeimbangan kelas, model yang dikembangkan mampu mencapai performa sangat tinggi dengan akurasi validasi sebesar 99,11% dan akurasi pengujian sebesar 100%. Metrik evaluasi yang mencakup precision, recall, dan f1-score semakin menguatkan bukti bahwa model ini robust dan andal dalam mengklasifikasikan lima kelas penyakit daun padi, yaitu Bacterial Leaf Blight, Brown Spot, Healthy, Narrow Brown Spot, dan Tungro. Selain itu, penerapan model terlatih ke dalam aplikasi berbasis Streamlit memberikan sebuah alat praktis yang dapat digunakan petani untuk mengidentifikasi penyakit daun padi secara real time. Aplikasi ini tidak hanya menampilkan hasil klasifikasi beserta tingkat kepercayaan (confidence score), tetapi juga memberikan rekomendasi penanganan. Dengan demikian, aplikasi ini mampu menjembatani teknologi *machine learning* tingkat lanjut dengan kebutuhan praktis di bidang pertanian. Sebagai kesimpulan, integrasi antara MobileNetV2 dan transfer learning telah terbukti menjadi solusi efektif dalam deteksi penyakit padi. Pendekatan ini berpotensi meningkatkan deteksi dini, mendukung pengambilan keputusan yang lebih tepat dalam manajemen penyakit, serta pada akhirnya dapat berkontribusi dalam peningkatan produktivitas padi dan ketahanan pangan.

Daftar Pustaka

- [1] A. Hasibuan, S. P. Nasution, F. A. Yani, H. A. Hasibuan, and N. Firzah, “Strategi Peningkatan Usaha Tani Padi Sawah Untuk Meningkatkan Perekonomian Masyarakat Desa,” *ABDIKAN: Jurnal Pengabdian Masyarakat Bidang Sains dan Teknologi*, vol. 1, no. 4, pp. 477–490, Nov. 2022, doi: 10.55123/abdiikan.v1i4.1095.
- [2] R. Laraswati, U. Kulsim, and E. P. Ramdan, “Efikasi Ekstrak Sirih, Rimpang Lengkuas dan Kunyit terhadap Penekanan Pertumbuhan *Xanthomonas oryzae*,” 2021.
- [3] Y. F. Rachman, P. Susanti, A. B. R. P. A. Putra, and N. I. Rahmawati, “Sistem Informasi Deteksi Penyakit Pada Tanaman Padi Menggunakan Metode CNN,” *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 4, no. 3, pp. 1193–1204, Nov. 2024, doi: 10.51454/decode.v4i3.846.
- [4] J. J. Hidayat, C. Setyowati, and A. P. Werdana, “Analisis Penyakit pada Daun Padi Menggunakan VGG-16 Transfer Learning dan Teknik Segmentasi K-Mean,” *Jurnal Media Infotama*, vol. 21, no. 1, 2025. [Online]. Available: www.kaggle.com
- [5] I. F. Annur, J. Umami, M. N. Annafii, N. Trisnaningrum, and O. V. Putra, “Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetV2,” *Fountain of Informatics Journal*, vol. 8, no. 1, pp. 7–14, May 2023, doi: 10.21111/fij.v8i1.9419.
- [6] O. V. Putra, M. Z. Mustaqim, D. Muriatmoko, J. Teknik Informatika, and F. Sains dan Teknologi, “Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2,” 2023.
- [7] D. Husen, “Evaluasi Teknik Augmentasi Data Untuk Klasifikasi Tumor Otak Menggunakan CNN Pada Citra MRI,” *Husem*, 2021.
- [8] Y. F. Rachman, P. Susanti, A. B. R. P. A. Putra, and N. I. Rahmawati, “Sistem Informasi Deteksi Penyakit Pada Tanaman Padi Menggunakan Metode CNN,” *Decode*, vol. 4, no. 3, pp. 1193–1204, Nov. 2024, doi: 10.51454/decode.v4i3.846.
- [9] J. J. Hidayat, C. Setyowati, and A. P. Werdana, “Analisis Penyakit pada Daun Padi Menggunakan VGG-16 Transfer Learning dan Teknik Segmentasi K-Mean,” *Jurnal Media Infotama*, 2025. [Online]. Available: www.kaggle.com
- [10] I. F. Annur, J. Umami, M. N. Annafii, N. Trisnaningrum, and O. V. Putra, “Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetV2,” *Fountain of Informatics Journal*, vol. 8, no. 1, pp. 7–14, May 2023, doi: 10.21111/fij.v8i1.9419.
- [11] H. Ning, S. Liu, Q. Zhu, and T. Zhou, “Convolutional neural network in rice disease recognition: accuracy, speed and lightweight,” *Frontiers in Plant Science*, 2023, doi: 10.3389/fpls.2023.1269371.

- [12] G. Latif et al., "Deep Learning Utilization in Agriculture: Detection of Rice Plant Diseases Using an Improved CNN Model," *Plants*, vol. 11, no. 17, Sep. 2022, doi: 10.3390/plants11172230.
- [13] A. R. Hermanto, A. Aziz, and S. Sudianto, "Perbandingan Arsitektur MobileNetV2 dan ResNet50 untuk Klasifikasi Jenis Buah Kurma," *Jurnal Sistem dan Teknologi Informasi*, vol. 12, no. 4, 2024, doi: 10.26418/justin.v12i4.80358.
- [14] A. Jalil, A. Homaidi, and Z. Fatah, "Implementasi Algoritma SVM Untuk Klasifikasi Status Stunting Pada Balita," *G-Tech: Jurnal Teknologi Terapan*, vol. 8, no. 3, pp. 2070–2079, Jul. 2024, doi: 10.33379/gtech.v8i3.4811.
- [15] R. Laraswati, E. P. Ramdan, U. Kulsum, and B. B. POPT, "Identifikasi Penyebab Penyakit Hawar Daun Bakteri Pada Kombinasi Pola Tanam SRI dan Jajar Legowo," *AGROPROSS*, 2021, doi: 10.25047/agropross.2021.234.
- [16] A. Walascha et al., "Inventarisasi Jenis Penyakit yang Menyerang Daun Tanaman Padi," *Prosiding SEMNAS BIO*, 2021.
- [17] W. Ratna Rohaeni and D. Yuliani, "Keragaman Morfologi Daun Padi Lokal Indonesia dan Korelasinya dengan Ketahanan Penyakit Hawar Daun Bakteri," *JIPI*, vol. 24, no. 3, pp. 258–266, 2019, doi: 10.18343/jipi.24.3.258.
- [18] R. A. W. Atmaja, S. J. Santosa, and S. Siswadi, "Kajian Pupuk Kandang terhadap Intensitas Penyakit Bercak Coklat Sempit," *Jurnal Inovasi Pertanian*, vol. 22, no. 1, 2020.
- [19] M. Sutrawati, Y. Sariyah, P. Priyatiningih, and F. T. Ladja, "Deteksi Virus Tungro Pada Padi di Bengkulu," *Jurnal Ilmu-Ilmu Pertanian Indonesia*, vol. 21, no. 2, pp. 99–102, Dec. 2019, doi: 10.31186/jipi.21.2.99-102.
- [20] I. R. Huriah, A. I. S. Widianingrum, and U. Muhammadiyah Riau, "Optimasi Augmentasi Data Berbasis Synonym Replacement," *Komputa*, vol. 14, no. 1, 2025, doi: 10.34010/komputa.v14i1.
- [21] H. Zhou, J. Deng, D. Cai, X. Lv, and B. M. Wu, "Effects of Image Dataset Configuration on the Accuracy of Rice Disease Recognition Based on CNN," *Frontiers in Plant Science*, vol. 13, Jul. 2022, doi: 10.3389/fpls.2022.910878.
- [22] R. R. Sani, Y. A. Pratiwi, S. Winarno, E. D. Udayanti, and F. A. Zami, "Analisis Perbandingan Algoritma NBC dan SVM untuk Klasifikasi Hoax," 2022.
- [23] R. Mardianto, S. Quinevera, and S. Rochimah, "Perbandingan Metode RF, CNN, dan SVM Untuk Klasifikasi Jenis Mangga," *JACOST*, vol. 5, no. 1, pp. 63–71, May 2024, doi: 10.52158/jacost.v5i1.742.
- [24] S. Dewi et al., "Analisis Sentimen Aplikasi WhatsApp Berdasarkan Ulasan di PlayStore," *AJST*, vol. 2, no. 2, 2024. [Online]. Available: <http://jurnal.ardenjaya.com/index.php/ajst>
- [25] J. Digital and T. Informasi, "Prediksi Penyakit Jantung Berbasis Machine Learning Menggunakan Metode K-NN," *Jurnal Digital*, vol. 7, no. 2, pp. 14–20, 2024, doi: 10.32502/digital.v7i2.9429.
- [26] M. Julkarnain and M. Yustiardin, "Penerapan Algoritma Naive Bayes dalam Memprediksi Lulus Tepat Waktu Mahasiswa," *Digital Transformation Technology*, vol. 4, no. 2, pp. 848–858, Dec. 2024, doi: 10.47709/digitech.v4i2.4963.