

Deteksi Penyakit Daun Padi Menggunakan MobileNetV2: Pendekatan Deep Learning untuk Meningkatkan Ketahanan Produksi Pangan

^{1*}**Rizma Agustin, ²Mediana Nurlailli, ³Khaila Puteri Yuanda,
⁴Bagus Ari Sudamto**

^{1,2,3,4}Sistem Informasi, Universitas Nusantara PGRI Kediri

E-mail: ^{*}rizmaagustin66@gmail.com, ²mediananurlailli@gmail.com,

³khailaputeri825@gmail.com, ⁴argaay99@gmail.com

Penulis Korespondens : Rizma Agustin

Abstrak — Tanaman padi merupakan komoditas utama ketahanan pangan di Indonesia, namun rentan terhadap serangan penyakit daun, terutama di daerah terpencil dengan akses terbatas. Penelitian ini membandingkan beberapa arsitektur deep learning seperti CNN, ResNet, EfficientNetB0, DenseNet121, dan MobileNetV2, serta model machine learning klasik seperti SVM, Random Forest, Naive Bayes, XGBoost, dan LightGBM. Dataset dari Kaggle mencakup 120 citra tiga jenis penyakit: bacterial leaf blight, brown spot, dan leaf smut. Hasil menunjukkan bahwa MobileNetV2, dengan sekitar 2,4 juta parameter dan citra 224×224 piksel, mencapai akurasi tertinggi sebesar 91,67%, dengan nilai rata-rata precision, recall, dan f1-score sebesar 0,92. Model ini diintegrasikan ke platform website untuk mendeteksi penyakit daun padi secara langsung tanpa alat khusus. MobileNetV2 terbukti efisien dan cocok untuk petani di lapangan.

Kata Kunci — Deep Learning, MobileNetV2, Penyakit Daun Padi, Platform Website

Abstract — *Rice is a major food security commodity in Indonesia, but it is susceptible to leaf disease attacks, especially in remote areas with limited access. This study compares several deep learning architectures such as CNN, ResNet, EfficientNetB0, DenseNet121, and MobileNetV2, as well as classical machine learning models such as SVM, Random Forest, Naive Bayes, XGBoost, and LightGBM. The dataset from Kaggle includes 120 images of three types of diseases: bacterial leaf blight, brown spot, and leaf smut. The results show that MobileNetV2, with around 2.4 million parameters and 224×224 pixel images, achieves the highest accuracy of 91.67%, with an average value of precision, recall, and f1-score of 0.92. This model is integrated into a website platform to detect rice leaf diseases directly without special tools. MobileNetV2 is proven to be efficient and suitable for farmers in the field.*

Keywords — Deep Learning, MobileNetV2, Rice Leaf Diseases, Website Platform

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Padi (*Oryza sativa*) merupakan salah satu komoditas utama yang menjadi tulang punggung ketahanan pangan di Indonesia. Produktivitas tanaman padi sangat dipengaruhi oleh kesehatan daun, yang sering kali terancam oleh berbagai penyakit seperti Bacterial leaf blight, Brown spot, dan Leaf smut. Penyakit ini dapat menyebabkan penurunan hasil panen secara

signifikan apabila tidak dideteksi dan ditangani sejak dini. Oleh karena itu, deteksi dini penyakit daun padi sangat penting untuk menjaga produksi pangan nasional.

Dalam beberapa tahun terakhir, deteksi penyakit daun padi telah banyak dikembangkan menggunakan pendekatan berbasis citra digital dan machine learning. Metode klasik seperti K-Nearest Neighbor (KNN) dengan fitur Gray Level Co-occurrence Matrix (GLCM) dan Canny Edge Detection telah digunakan oleh Verawati [1]. Selain itu, Support Vector Machine (SVM) dengan fitur mendalam (deep feature) juga telah diterapkan dalam klasifikasi penyakit daun padi oleh Margarita [2]. Kombinasi beberapa algoritma klasik seperti Decision Tree, Random Forest, Naïve Bayes, dan SVM juga masih menjadi alternatif yang efektif, sebagaimana ditunjukkan oleh Purnamawati et al. [3] dan Rahmi & Saputra [4].

Seiring kemajuan teknologi, arsitektur deep learning, khususnya Convolutional Neural Network (CNN), mulai banyak diadopsi untuk meningkatkan akurasi klasifikasi penyakit daun. Oktaviana [5] memanfaatkan model ResNet101 untuk klasifikasi penyakit padi, sementara Khoiruddin [6] menggunakan CNN murni untuk tujuan serupa. Pengembangan arsitektur CNN yang lebih ringan dan efisien juga mulai menjadi fokus, terutama untuk implementasi di perangkat dengan sumber daya terbatas. Saputra [7] menggabungkan CNN dengan MobileNet dalam aplikasi deteksi penyakit daun padi, sedangkan Annur [8] dan Putra [9] [10] menekankan penggunaan MobileNetV2 karena efisiensi komputasi dan kemampuannya untuk dijalankan di perangkat berbasis web maupun mobile.

Selain MobileNetV2, arsitektur lain seperti DenseNet-169 dan EfficientNet-B3 juga mulai dieksplorasi dalam konteks deteksi penyakit tanaman padi. Asseweth [11] menggunakan DenseNet-169, dan Ayuni [12] menerapkan EfficientNet-B3 dengan teknik augmentasi data untuk meningkatkan performa klasifikasi. Pendekatan ini menunjukkan potensi yang besar dalam meningkatkan akurasi dan daya tahan model terhadap variasi data.

Meskipun mayoritas penelitian fokus pada akurasi model, beberapa studi lain juga memperluas aplikasi CNN pada klasifikasi tanaman hias seperti yang dilakukan oleh Suswati [13], dan penyakit daun pisang oleh Pratama [14], yang menunjukkan fleksibilitas metode ini pada berbagai jenis tanaman. Faturachman [15] pun masih mengandalkan metode klasik seperti Local Binary Pattern (LBP) dan SVM dalam mendeteksi penyakit daun singkong, yang menunjukkan bahwa metode tradisional masih relevan sebagai pembanding dan alternatif.

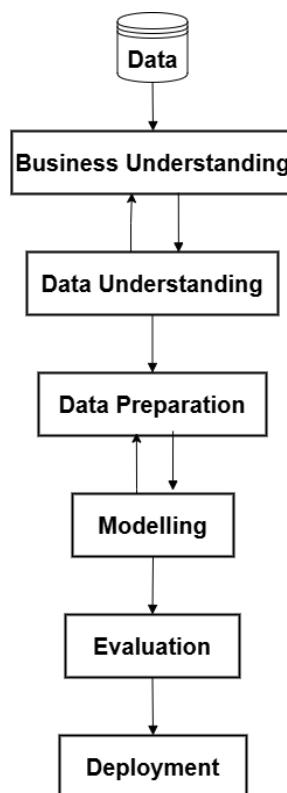
Pada praktiknya, pengaplikasian model deteksi penyakit ini lebih efektif bila diintegrasikan ke dalam platform yang mudah diakses oleh pengguna, seperti website. Dengan menggunakan arsitektur MobileNetV2 yang ringan dan cepat, deteksi penyakit daun padi dapat dilakukan secara real-time melalui website tanpa memerlukan perangkat keras yang berat. Hal ini membuka peluang bagi petani atau pihak terkait untuk memanfaatkan teknologi secara praktis dan efisien tanpa harus bergantung pada aplikasi mobile atau perangkat khusus.

Penelitian ini bertujuan mengembangkan sistem deteksi penyakit daun padi berbasis deep learning dengan menggunakan MobileNetV2, yang diimplementasikan pada platform website. Pendekatan ini menitikberatkan pada efisiensi komputasi, kemudahan akses, dan akurasi klasifikasi, sehingga sistem dapat digunakan secara langsung di lapangan oleh para petani dan

pengelola pertanian. Dengan demikian, diharapkan penelitian ini dapat memberikan kontribusi nyata dalam memperkuat ketahanan pangan nasional melalui deteksi dini penyakit padi yang efektif dan mudah diakses.

II. METODE

Penelitian ini menggunakan pendekatan CRISP-DM (Cross-Industry Standard Process for Data Mining) sebagai kerangka kerja utama dalam menyusun tahapan penelitian, sebagaimana dijelaskan oleh Ristyawan et al. [16]. Pendekatan ini mencakup enam fase utama: business understanding, data understanding, data preparation, modeling, evaluation, dan deployment. Berikut adalah gambar langkah-langkah dari metode yang digunakan.



Gambar 1. Model CRISP-DM

2.1 Business Understanding

Penelitian ini dilatarbelakangi oleh permasalahan rendahnya produktivitas pertanian akibat penyakit pada tanaman padi, khususnya pada bagian daun yang sering diserang oleh penyakit seperti Leaf Smut, Brown Spot, dan Bacterial Leaf Blight. Masalah ini diperparah oleh keterbatasan akses teknologi di daerah pedesaan, yang menyebabkan lambatnya deteksi dini dan penanganan penyakit. Tujuan utama dari penelitian ini adalah membangun sistem deteksi penyakit daun padi berbasis citra digital menggunakan model deep learning ringan, yang dapat diakses secara mudah oleh petani melalui antarmuka web.

2.2 Data Understanding

Tahap ini melibatkan pemahaman terhadap dataset Rice Leaf Diseases yang diperoleh dari platform Kaggle. Dataset tersebut berisi 120 gambar daun padi yang terbagi merata ke dalam tiga kelas penyakit, yaitu Leaf Smut, Brown Spot, dan Bacterial Leaf Blight. Setiap kelas terdiri atas 40 gambar. Proses eksplorasi data mencakup pemeriksaan resolusi gambar, keseimbangan kelas, serta kejelasan visual dari gejala penyakit yang tampak pada daun untuk memastikan kualitas data yang memadai untuk pelatihan model.

2.3 Data Preparation

Pada tahap ini dilakukan serangkaian proses pra-pemrosesan gambar. Seluruh citra diubah ukurannya menjadi 224x224 piksel dan dinormalisasi ke dalam rentang nilai antara 0 hingga 1. Label kelas dikonversi ke dalam format numerik menggunakan LabelEncoder, kemudian diterapkan One-hot Encoding agar sesuai dengan format input model. Selanjutnya, dataset dibagi menjadi data pelatihan dan pengujian dengan rasio 80:20 secara stratified. Untuk mengatasi keterbatasan jumlah data, diterapkan teknik augmentasi gambar seperti rotasi, flipping horizontal, zoom, dan pergeseran posisi guna meningkatkan variasi citra dan kemampuan generalisasi model.

2.4 Modeling

Model utama yang digunakan dalam penelitian ini adalah MobileNetV2, yang dipilih karena arsitekturnya ringan dan efisien, cocok untuk implementasi lokal di perangkat dengan keterbatasan sumber daya. Model dikembangkan tanpa bobot pralatin dan lapisan klasifikasi bawaan, melainkan disusun ulang dengan menambahkan Global Average Pooling, lapisan Dense dengan aktivasi ReLU, Dropout sebesar 0.5, dan lapisan output Dense beraktivasi softmax untuk klasifikasi multi-kelas.

Sebagai bandingan, dilakukan pula pelatihan beberapa model lain untuk mengevaluasi efektivitas MobileNetV2. Model bandingan ini mencakup:

- CNN Sederhana, yang dibangun dari nol sebagai baseline model.
- Model Pretrained seperti ResNet, ResNet50, EfficientNetB0, dan DenseNet121, yang diuji dengan pendekatan fine-tuning untuk mengetahui performa arsitektur yang lebih kompleks.
- Algoritma Machine Learning Klasik seperti SVM, Random Forest, Naive Bayes, XGBoost, dan LightGBM, yang dilatih menggunakan fitur hasil ekstraksi dari gambar (misalnya vektor dari layer convolution terakhir model pretrained).

Seluruh model ini dibandingkan berdasarkan metrik evaluasi yang konsisten, dan hasilnya digunakan untuk menilai keunggulan relatif MobileNetV2 sebagai model akhir yang digunakan untuk deployment.

2.5 Evaluation

Evaluasi dilakukan menggunakan classification report yang mencakup metrik precision, recall, f1-score, dan support. Metrik ini dipilih untuk menilai performa model secara menyeluruh dalam mengklasifikasikan tiga jenis penyakit daun padi. Selain itu, confusion matrix digunakan untuk melihat akurasi prediksi per kelas. Hasil evaluasi ini akan menjadi dasar dalam menentukan model terbaik yang akan diterapkan pada sistem klasifikasi berbasis website.

2.6 Deployment

Tahap akhir adalah implementasi sistem secara lokal. Model MobileNetV2 yang telah dilatih disimpan dalam format .h5 dan diintegrasikan ke dalam aplikasi web berbasis Laravel. Laravel

digunakan sebagai backend dan frontend untuk menangani antarmuka pengguna, sedangkan Flask API digunakan untuk melayani prediksi model. Ketika pengguna mengunggah gambar daun padi melalui web, sistem akan mengirim gambar tersebut ke Flask API yang menjalankan model klasifikasi, kemudian mengembalikan hasil prediksi ke halaman Laravel secara real-time. Seluruh proses ini dilakukan secara lokal, memungkinkan pengguna di daerah dengan koneksi terbatas tetap dapat memanfaatkan teknologi deteksi penyakit berbasis AI.

III. HASIL DAN PEMBAHASAN

3.1 Arsitektur MobileNetV2

Penelitian ini menggunakan arsitektur MobileNetV2 sebagai model dasar dalam kerangka transfer learning. MobileNetV2 dirancang secara efisien dengan memanfaatkan depthwise separable convolutions dan inverted residual blocks yang dikombinasikan dengan linear bottlenecks untuk mengurangi kompleksitas komputasi. Model diinisialisasi menggunakan bobot pralatih dari dataset ImageNet (weights='imagenet') dengan menghapus lapisan klasifikasi atas (include_top=False), sehingga hanya fitur-fitur visual yang dibawa ke model ini.

Lapisan klasifikasi kustom kemudian ditambahkan untuk mengakomodasi tiga kelas penyakit daun padi. Seluruh jaringan, termasuk sebagian MobileNetV2 dan lapisan kustom, dilatih ulang (fine-tuning) menggunakan dataset penyakit daun padi untuk mengoptimalkan performa klasifikasi. Pelatihan dilakukan selama 50 epoch dengan penggunaan callback seperti EarlyStopping dan ReduceLROnPlateau guna menghindari overfitting dan menyesuaikan laju pembelajaran. Pemilihan MobileNetV2 dilatarbelakangi oleh efisiensi arsitekturnya yang memiliki sekitar 2,4 juta parameter, jauh lebih ringan dibanding model besar seperti ResNet50. Hal ini sangat relevan untuk implementasi di perangkat dengan spesifikasi rendah, seperti smartphone yang digunakan oleh petani di daerah terpencil.

Model: "functional_2"		
Layer (type)	Output Shape	Param #
input_layer_4 (InputLayer)	(None, 224, 224, 3)	0
sequential (Sequential)	(None, 224, 224, 3)	0
true_divide_1 (TrueDivide)	(None, 224, 224, 3)	0
subtract_1 (Subtract)	(None, 224, 224, 1)	0
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,964
global_average_pooling2d_1 (GlobalAveragePooling2D)	(None, 1280)	0
batch_normalization_1 (BatchNormalization)	(None, 1280)	5,120
dense_3 (Dense)	(None, 128)	163,968
dropout_2 (Dropout)	(None, 128)	0
dense_4 (Dense)	(None, 64)	8,256
dropout_3 (Dropout)	(None, 64)	0
dense_5 (Dense)	(None, 3)	195

Total params: 2,435,523 (9.29 MB)
Trainable params: 2,334,723 (8.91 MB)
Non-trainable params: 100,800 (393.75 KB)

Gambar 2. Arsitektur Model MobileNetV2

3.2 Kinerja Model MobileNetV2

Setelah proses pelatihan selesai, kinerja model MobileNetV2 dievaluasi menggunakan data uji (test set) yang belum pernah dilihat selama pelatihan. Evaluasi bertujuan untuk mengukur kemampuan generalisasi model terhadap data baru. Metrik evaluasi yang digunakan meliputi akurasi keseluruhan dan classification report (precision, recall, dan F1-score) per kelas. Berikut adalah hasil evaluasi model:

Classification Report:				
	precision	recall	f1-score	support
Bacterial leaf blight	0.89	1.00	0.94	8
Brown spot	0.89	1.00	0.94	8
Leaf smut	1.00	0.75	0.86	8
accuracy			0.92	24
macro avg	0.93	0.92	0.91	24
weighted avg	0.93	0.92	0.91	24

Gambar 3. Tabel Classification Report MobileNetV2

Model MobileNetV2 menunjukkan akurasi sebesar 91,67% pada data uji. Berdasarkan classification report, model memiliki recall tinggi untuk kelas Bacterial Leaf Blight dan Brown Spot, yang menunjukkan kemampuannya dalam mengidentifikasi sebagian besar kasus penyakit tersebut. Sementara itu, precision untuk kelas Leaf Smut mencapai 1.00, namun recall-nya sedikit lebih rendah (0.75), mengindikasikan bahwa beberapa kasus tidak terdeteksi. Meskipun MobileNetV2 memiliki keunggulan dalam efisiensi, model ini masih memiliki keterbatasan dalam mendeteksi citra dengan noise tinggi atau pencahayaan buruk, yang umum terjadi di lapangan. Model ini berpotensi ditingkatkan dengan menggabungkan preprocessing berbasis segmentasi daun atau transfer learning dari domain pertanian.

Temuan ini konsisten dengan hasil penelitian oleh Annur [8], yang menggunakan MobileNetV2 dalam klasifikasi penyakit leaf blast dan melaporkan akurasi di atas 90%. Penelitian Saputra [7] juga mendukung efektivitas MobileNet, meskipun tidak menggunakan versi V2, dalam deteksi penyakit daun padi. Penelitian Oktaviana [5] menggunakan arsitektur ResNet101 dan melaporkan akurasi tinggi, tetapi model tersebut memiliki parameter lebih besar dan waktu pelatihan lebih lama dibanding MobileNetV2. Hal ini menegaskan bahwa MobileNetV2 menjadi pilihan efisien dalam konteks keterbatasan perangkat keras, tanpa mengorbankan akurasi.

3.3 Perbandingan dengan Model Lain

Untuk memastikan bahwa MobileNetV2 adalah model yang optimal, dilakukan perbandingan dengan beberapa model pembanding, baik dari ranah deep learning maupun machine learning klasik. Model pembanding meliputi:

- CNN sederhana (dibangun dari nol)
 - Model pretrained: ResNet, ResNet50, EfficientNetB0, DenseNet121
 - Machine Learning klasik: SVM, Random Forest, Naive Bayes, XGBoost, dan LightGBM
- Perbandingan dilakukan menggunakan metrik akurasi pada data uji.

	Model	Accuracy	
0	MobileNetV2	0.916667	
1	CNN	0.791667	
2	SVM	0.750000	
3	Random Forest	0.750000	
4	LightGBM	0.708333	
5	XGBoost	0.625000	
6	ResNet (Custom CNN)	0.625000	
7	Naive Bayes	0.541667	
8	ResNet50	0.333333	
9	EfficientNetB0	0.333333	
10	DenseNet121	0.250000	

Gambar 4. Perbandingan akurasi antar model

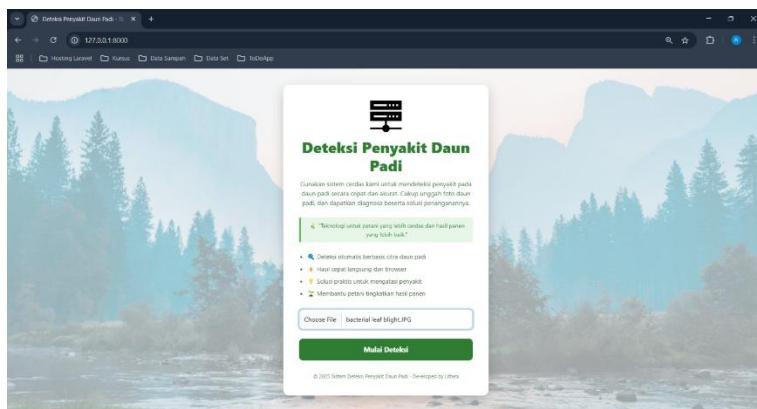
Hasil menunjukkan bahwa MobileNetV2 memiliki akurasi tertinggi dibandingkan model lainnya. Meskipun beberapa model lain seperti ResNet50 dan DenseNet121 juga memberikan hasil yang baik, efisiensi arsitektur MobileNetV2 membuatnya unggul dalam hal kecepatan dan kebutuhan sumber daya. Model klasik seperti SVM dan Naive Bayes menunjukkan kinerja yang jauh lebih rendah karena kurang mampu menangkap fitur spasial kompleks dalam citra. Hal ini menegaskan bahwa pendekatan berbasis deep learning, khususnya arsitektur ringan seperti MobileNetV2, lebih tepat untuk klasifikasi penyakit daun berbasis gambar. Dengan mempertimbangkan hasil dan efisiensi, pendekatan ini tidak hanya sebanding dengan penelitian terdahulu yang fokus pada performa model, tetapi juga unggul dalam aspek implementasi nyata di lapangan, sebuah kontribusi praktis yang jarang disentuh dalam kajian sebelumnya.

Penurunan performa arsitektur seperti DenseNet121 dan EfficientNetB0 dalam penelitian ini berbanding terbalik dengan hasil penelitian oleh Ayuni [12] dan Asseweth [11], yang masing-masing melaporkan performa tinggi pada model tersebut. Hal ini kemungkinan besar disebabkan oleh perbedaan teknik augmentasi, jumlah data latih, serta konfigurasi pelatihan yang digunakan. Dengan demikian, meskipun model-model kompleks dapat memberikan hasil baik dalam beberapa studi, efektivitasnya sangat bergantung pada konteks implementasi dan ketersediaan data. Sebaliknya, MobileNetV2 terbukti lebih konsisten memberikan performa tinggi pada dataset terbatas dan cocok untuk kebutuhan praktis di lapangan, sebagaimana juga disarankan dalam penelitian Putra [9].

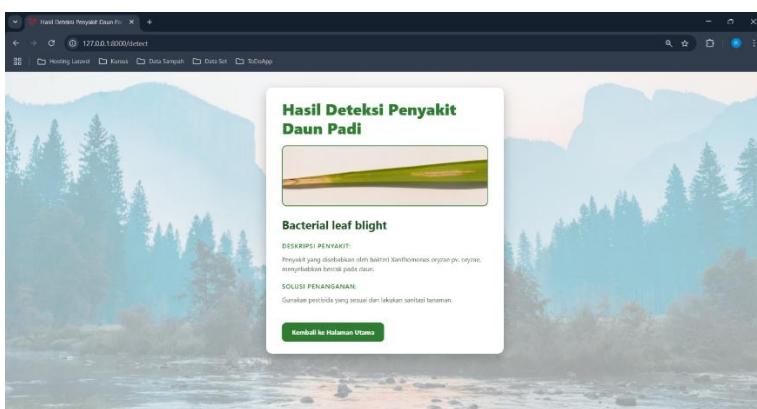
3.4 Implementasi pada Platform Website

Model MobileNetV2 yang telah dilatih dan disimpan dalam format .h5 diintegrasikan ke dalam platform web berbasis Laravel. Antarmuka pengguna dikembangkan menggunakan Laravel sebagai frontend dan backend, sedangkan proses prediksi model dijalankan melalui Flask API. Alur kerja sistem adalah sebagai berikut:

1. Pengguna mengunggah gambar daun padi melalui website.
2. Gambar dikirim ke server lokal yang menjalankan Flask.
3. Flask API memproses gambar menggunakan model MobileNetV2.
4. Hasil prediksi dikirim kembali ke antarmuka Laravel secara real-time.



Gambar 5. Tampilan unggah gambar daun padi



Gambar 6. Tampilan hasil deteksi penyakit daun padi

Sistem ini dirancang untuk berfungsi secara lokal, sehingga tetap dapat digunakan meskipun koneksi internet terbatas. Penggunaan API lokal memungkinkan proses prediksi berlangsung cepat (kurang dari 2 detik), memberikan pengalaman pengguna yang responsif. Keunggulan sistem ini adalah kemudahannya digunakan oleh petani tanpa perlu perangkat khusus atau koneksi internet stabil. Namun demikian, pengujian lebih lanjut terhadap pengguna akhir masih diperlukan untuk mengevaluasi tingkat keterpahaman antarmuka dan akurasi prediksi dalam praktik lapangan.

Dengan adanya sistem yang dapat mendeteksi penyakit daun padi secara cepat, akurat, dan tanpa memerlukan perangkat khusus, petani dapat melakukan tindakan preventif lebih awal sebelum penyakit menyebar luas. Hal ini secara langsung membantu mempertahankan kualitas dan kuantitas hasil panen, terutama di daerah terpencil yang rawan keterlambatan deteksi penyakit. Oleh karena itu, solusi ini tidak hanya memberikan dampak teknologi, tetapi juga berkontribusi terhadap peningkatan ketahanan produksi pangan nasional melalui intervensi dini berbasis kecerdasan buatan.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi penyakit daun padi berbasis arsitektur MobileNetV2 yang diimplementasikan dalam bentuk website interaktif. Dengan efisiensi tinggi dan jumlah parameter sekitar 2,4 juta, MobileNetV2 mampu menghasilkan akurasi tertinggi sebesar 91,67%, mengungguli berbagai arsitektur deep learning dan machine learning lainnya. Model CNN konvensional menunjukkan akurasi sebesar 79,17%, sementara model klasik seperti SVM dan Random Forest masing-masing mencapai 75%, dan LightGBM sebesar 70,83%. Di sisi lain, model XGBoost dan ResNet (Custom CNN) memperoleh akurasi sebesar 62,5%, sedangkan Naive Bayes hanya mencapai 54,17%. Arsitektur yang lebih kompleks seperti ResNet50, EfficientNetB0, dan DenseNet121 justru menghasilkan akurasi yang lebih rendah, yaitu 33,33%, 33,33%, dan 25% secara berturut-turut.

MobileNetV2 dipilih sebagai model utama karena kemampuannya melakukan klasifikasi dengan cepat dan akurat, bahkan pada perangkat dengan sumber daya terbatas. Sistem yang dikembangkan memungkinkan pengguna mengunggah gambar daun padi langsung melalui website, yang kemudian secara otomatis diklasifikasikan ke dalam tiga kategori penyakit: Bacterial leaf blight, Brown spot, dan Leaf smut. Hasil ini menunjukkan bahwa pendekatan berbasis MobileNetV2 sangat efektif dan praktis untuk digunakan di lapangan, khususnya oleh petani, dalam mendekripsi penyakit daun padi secara dini tanpa memerlukan perangkat keras khusus. Ke depan, penelitian ini dapat dikembangkan lebih lanjut dengan pengujian pada skala data yang lebih besar dan integrasi ke perangkat mobile.

UCAPAN TERIMAKASIH

Penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada Universitas Nusantara PGRI Kediri atas dukungan fasilitas serta bimbingan akademik yang telah diberikan selama berlangsungnya penelitian ini. Penghargaan juga diberikan kepada Program Studi Sistem Informasi atas arahan dan kesempatan yang telah memungkinkan penulis untuk mengembangkan kemampuan dalam bidang akademik dan penelitian. Selain itu, seluruh dukungan dan partisipasi yang diberikan sangat membantu dalam kelancaran serta keberhasilan penelitian ini.

DAFTAR PUSTAKA

- [1] I. Verawati, “Klasifikasi Penyakit Daun Padi Menggunakan KNN dengan GLCM dan Canny Edge Detection,” *Jurnal Media Informatika Budidarma*, vol. 8, no. 1, p. 517, 2024.
- [2] D. MARGARITA, “Klasifikasi Penyakit Daun Padi Menggunakan Support Vector Machine Berdasarkan Fitur Mendalam (Deep Feature),” vol. 9, no. 4, pp. 1-21, 2024.
- [3] A. Purnamawati, “Deteksi Penyakit Daun pada Tanaman Padi Menggunakan Algoritma Decision Tree, Random Forest, Naïve Bayes, SVM dan KNN,” *InfoTekJar: Jurnal Nasional Informatika dan Teknologi Jaringan*, vol. 5, no. 1, pp. 212-215, 2020.

- [4] R. R. Burhanuddin, "Klasifikasi Penyakit Padi Melalui Citra Daun Menggunakan Metode Naive Bayes," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 2, 2024.
- [5] U. N. Oktaviana, "Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 6, pp. 1216-1222, 2021.
- [6] M. Khoiruddin, "Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network," *Journal of Dinda : Data Science, Information Technology, and Data Analytics*, vol. 2, no. 1, pp. 37-45, 2022.
- [7] R. A. Saputra, "Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi," *Swabumi*, vol. 9, no. 2, pp. 184-188, 2021.
- [8] I. F. Annur, "Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetv2," *Fountain of Informatics Journal*, vol. 8, no. 1, 2023.
- [9] O. V. Putra, "Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2," *Techno.Com*, vol. 22, no. 3, pp. 562-575, 2023.
- [10] O. V. Putra, "Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2," *Techno.Com*, vol. 22, no. 3, pp. 562-575, 2023.
- [11] Asseweth, "TANAMAN PADI MENGGUNAKAN ARSITEKTUR DENSENET-169 SKRIPSI OLEH : MUHAMMAD YAZID ABUD ASSEWETH FAKULTAS TEKNIK UNIVERSITAS MEDAN AREA MEDAN TANAMAN PADI MENGGUNAKAN ARSITEKTUR DENSENET-169 SKRIPSI Diajukan sebagai salah satu Syarat untuk Memperoleh Gelar Sa," 2024.
- [12] D. Putri Ayuni, "Augmentasi Data Pada Implementasi Convolutional Neural Network Arsitektur Efficientnet-B3 Untuk Klasifikasi Penyakit Daun Padi," *ZONAsi: Jurnal Sistem Informasi*, vol. 5, no. 2, pp. 239-249, 2023.
- [13] B. Suswati, "Implementasi Convolutional Neural Network pada Klasifikasi Citra Daun Tanaman Hias," *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 4, no. 2, pp. 554-565, 2024.
- [14] M. D. Pratama, "Klasifikasi Penyakit Daun Pisang menggunakan Convolutional Neural Network (CNN)," *Jurnal Teknologi Terpadu*, vol. 10, no. 1, pp. 1-6, 2024.
- [15] M. Faturrahman, "Deteksi Penyakit Pada Daun Singkong," vol. 11, no. 6, pp. 5805-5813, 2022.
- [16] A. Ristyawan, "Optimasi Preprocessing Model Random Forest Untuk Prediksi Stroke," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 12, no. 1, pp. 29-44, 2025.