

Klasifikasi Jenis Penyakit Tanaman Padi Menggunakan Arsitektur *MobileNetV2* Berbasis *Transfer Learning* Di Desa Karangraharja, Kabupaten Bekasi

¹Allya Putri Nadila Gustin, ²Jajam Haerul Jaman, ³Garno
^{1,2,3}Universitas Singaperbangsa Karawang,
Karawang

E-mail: ¹2210631170111@student.unsika.ac.id,
²jajam.haeruljaman@staff.unsika.ac.id, ³garno@staff.unsika.ac.id

ABSTRAK

Padi merupakan salah satu komoditas pangan penting di Indonesia, namun produktivitasnya sering dipengaruhi oleh penyakit tanaman yang dapat menurunkan hasil panen. Di Kabupaten Bekasi, khususnya Desa Karangraharja, identifikasi penyakit tanaman padi masih dilakukan secara manual melalui pengamatan visual pada daun sehingga bersifat subjektif dan bergantung pada pengalaman petani. Kondisi tersebut berpotensi menyebabkan kesalahan dalam klasifikasi dan penanganan penyakit. Perkembangan teknologi memungkinkan klasifikasi jenis penyakit padi dilakukan menggunakan pengolahan citra. Tujuan penelitian ini untuk mengklasifikasikan jenis penyakit tanaman padi berdasarkan citra daun, sesuai dengan kelas penyakitnya menggunakan teknik transfer learning. Tahapan penelitian dilakukan menggunakan metodologi CRISP-DM yang meliputi business understanding, data understanding, data preparation, modeling, evaluation, dan deployment. Data citra yang digunakan berjumlah 6.166 citra daun padi. Proses klasifikasi dilakukan menggunakan arsitektur MobileNetV2. Skenario terbaik diperoleh pada metode fine-tuning dengan pembagian data 80% training, 10% validation, dan 10% testing, yang menghasilkan akurasi sebesar 99% pada data testing dan 95% pada data baru.

Kata kunci : *Penyakit Tanaman Padi, MobileNetV2, CRISP-DM, fine-tuning*

ABSTRACT

Rice is an important food commodity in Indonesia, but its productivity is often affected by plant diseases that can reduce yields. In Bekasi Regency, particularly Karangraharja Village, rice plant disease identification is still done manually through visual observation of leaves, making it subjective and dependent on farmer experience. This condition has the potential to cause errors in disease classification and management. Technological developments allow the classification of rice disease types to be carried out using image processing. The purpose of this study was to classify rice plant diseases based on leaf images, according to their disease class using transfer learning techniques. The research stages were carried out using the CRISP-DM methodology, which includes business understanding, data understanding, data preparation, modeling, evaluation, and deployment. The image data used amounted to 6.166 rice leaf images. The classification process was carried out using the MobileNetV2 architecture. The best scenario was obtained by the fine-tuning method with a data division of 80% training, 10% validation, and 10% testing, which resulted in an accuracy of 99% on the testing data and 95% on the new data.

Keyword : *Rice Plant Disease, MobileNetV2, CRISP-DM, fine-tuning*

1. PENDAHULUAN

Padi merupakan komoditas pangan strategis yang berperan penting dalam menjaga ketahanan pangan Indonesia. Pada tahun 2025, produksi padi nasional mencapai 60,21 juta ton gabah kering giling (GKG) dengan luas panen 11,32 juta hektar (BPS, 2025). Selain itu, produksi beras untuk konsumsi penduduk mencapai 34,69 juta ton atau meningkat 13,29% dibandingkan tahun sebelumnya (BPS, 2025). Seiring dengan meningkatnya kebutuhan pangan akibat pertumbuhan penduduk, upaya menjaga dan meningkatkan produktivitas padi menjadi sangat penting untuk mendukung ketahanan pangan nasional.

Produktivitas padi masih menghadapi berbagai tantangan, salah satunya adalah serangan organisme pengganggu tanaman (OPT) yang dapat menyebabkan penurunan hasil hingga gagal panen (Pitriana et al., 2025). Menurut FAO, sekitar 20–40% kerugian produksi pangan dunia disebabkan oleh hama dan penyakit tanaman, sementara IRRI melaporkan bahwa petani padi dapat kehilangan hingga 37% hasil panen setiap tahunnya akibat faktor tersebut (Nurhaliza et al., 2025).

Salah satu daerah yang menghadapi permasalahan tersebut adalah Kabupaten Bekasi, yang merupakan sentra produksi padi di Provinsi Jawa Barat. Berdasarkan hasil wawancara dengan pihak Dinas Pertanian Kabupaten Bekasi, produktivitas padi selama periode 2021–2025 menunjukkan kecenderungan hubungan berbanding terbalik dengan luas lahan yang terserang penyakit. Penurunan luas serangan penyakit pada tahun 2023–2024 diikuti oleh peningkatan produktivitas padi, sedangkan peningkatan luas serangan penyakit pada tahun 2025 diikuti oleh penurunan produktivitas. Hal tersebut menunjukkan bahwa penyakit tanaman berkontribusi terhadap fluktuasi produktivitas padi di Kabupaten Bekasi.

Selain penyakit tanaman, produktivitas padi di Kabupaten Bekasi juga dipengaruhi oleh berbagai faktor lain seperti serangan penggerek batang padi, tikus, wereng batang coklat, dan kekeringan. Hasil wawancara dengan pihak Dinas Pertanian Kabupaten Bekasi menunjukkan bahwa penggerek batang padi dan kekeringan merupakan faktor yang paling dominan memengaruhi luas lahan terdampak pada periode 2024–2025. Adapun penyakit tanaman padi yang tercatat menyerang lahan pertanian di Kabupaten Bekasi meliputi penyakit blast daun dan hawar daun. Meskipun luas serangannya relatif lebih kecil dibandingkan faktor lainnya, kedua penyakit tersebut tetap berpotensi menurunkan produktivitas apabila tidak dideteksi dan ditangani sejak dini. Selain itu, identifikasi penyakit tanaman cenderung lebih kompleks dibandingkan hama karena gejalanya dipengaruhi oleh berbagai faktor dan disebabkan oleh patogen yang tidak dapat diamati secara langsung (Sutiharni et al., 2024).

Identifikasi penyakit tanaman padi yang dilakukan petani umumnya masih mengandalkan pengamatan visual terhadap gejala pada daun, seperti perubahan warna, bentuk, dan karakteristik lainnya. Metode ini sangat bergantung pada pengalaman petani sehingga rentan menimbulkan kesalahan identifikasi, terutama ketika gejala antar penyakit memiliki kemiripan. Akibatnya, penanganan penyakit yang diberikan dapat menjadi kurang tepat. Oleh karena itu, diperlukan teknologi pengolahan citra berbasis deep learning yang mampu mengklasifikasikan penyakit tanaman padi secara cepat, akurat, dan objektif (Lizard Sambawo Dimara et al., 2025).

Penelitian klasifikasi penyakit tanaman menggunakan deep learning telah banyak dilakukan, salah satunya dengan memanfaatkan teknik transfer learning pada arsitektur MobileNetV2. Penelitian sebelumnya menunjukkan bahwa MobileNetV2 mampu

menghasilkan akurasi klasifikasi yang tinggi, mencapai 96%–99%, serta memiliki jumlah parameter yang relatif kecil sehingga lebih efisien untuk implementasi pada perangkat dengan sumber daya terbatas (Putra et al., 2023; Velarati et al., 2024). Berdasarkan hasil tersebut, penelitian ini menerapkan transfer learning menggunakan MobileNetV2 untuk mengembangkan model klasifikasi penyakit daun padi yang akurat dan efisien sebagai alat bantu identifikasi penyakit bagi petani.

2. LANDASAN TEORI

2.1 Klasifikasi

Klasifikasi merupakan salah satu metode dalam *supervised learning* yang digunakan untuk menganalisis data latih dan membangun model yang mampu memprediksi atau menentukan kelas dari suatu objek yang sebelumnya belum diketahui (Adhitya et al., 2023).

2.2 Penyakit Tanaman Padi

Penyakit pada tanaman padi merupakan salah satu faktor utama yang menyebabkan kehilangan hasil panen dan penurunan produktivitas. Penyakit tanaman didefinisikan sebagai kondisi abnormal pada jaringan tanaman yang dapat disebabkan oleh organisme patogen seperti bakteri, jamur, virus, maupun faktor lingkungan yang tidak mendukung pertumbuhan tanaman (Roeswitawati et al., 2023).

Salah satu penyakit penting pada tanaman padi adalah Bacterial Leaf Blight (BLB) atau hawar daun bakteri yang disebabkan oleh bakteri *Xanthomonas oryzae* pv. *oryzae* (Xoo). Penyakit ini ditandai dengan munculnya bercak keabuan pada daun yang berkembang menjadi lesi memanjang, menyebabkan daun menguning, mengering, hingga menurunkan kualitas pengisian gabah.

Kehilangan hasil akibat serangan BLB dapat mencapai 15–80% tergantung tingkat keparahan dan fase pertumbuhan tanaman saat terinfeksi (Laraswati et al., 2021; Sudir et al., 2022). Pengendalian penyakit ini dapat dilakukan melalui penggunaan varietas tahan, pengelolaan air yang tepat, sanitasi lahan, pemupukan berimbang, serta pemanfaatan agens hayati dan bakterisida apabila diperlukan (Distankan, 2025).

Penyakit penting lainnya adalah Leaf Blast atau blas daun yang disebabkan oleh jamur *Pyricularia oryzae*. Gejala khas penyakit ini berupa bercak berbentuk belah ketupat dengan bagian tengah berwarna abu-abu dan tepi berwarna cokelat kemerahan. Penyakit blas dapat menyerang berbagai bagian tanaman padi dan berpotensi menurunkan hasil panen secara signifikan. Pengendalian penyakit blas dapat dilakukan melalui penggunaan varietas tahan, pengaturan waktu dan pola tanam, pengelolaan jarak tanam untuk mengurangi kelembaban, serta aplikasi fungisida sebagai tindakan pengendalian apabila diperlukan (Silfia, 2023; BPTP, 2022).

2.3 CRISP-DM

CRISP-DM (*Cross Industry Standard Process for Data Mining*) adalah metodologi atau kerangka kerja dalam data mining yang digunakan untuk mengolah dan menganalisis data secara sistematis (Sastya et al., 2023). Adapun tahapannya adalah *Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluasi, dan Deployment*

2.4 Computer Vision

Computer Vision merupakan cabang ilmu dan teknologi yang memungkinkan mesin untuk "melihat", yaitu kemampuan untuk menangkap dan memahami

informasi dari data visual seperti gambar atau video. Informasi yang diproses bisa berasal dari berbagai bentuk data visual, mulai dari gambar diam, rangkaian video, hingga data multidimensi seperti hasil pemindaian medis (Setiawan et al., 2021).

2.5 Transfer Learning

Transfer learning merupakan suatu teknik dalam machine learning yang memanfaatkan model yang telah dilatih sebelumnya (pre-trained) sebagai dasar untuk menyelesaikan tugas baru yang masih berkaitan (Faturrahman et al., 2023).

2.6 MobileNetV2

MobileNetV2 merupakan salah satu arsitektur *Convolutional Neural Network* (CNN) yang merupakan pengembangan dari *MobileNetV1*. Pada arsitektur ini ditambahkan residual terbalik (*inverted residual*) dengan *linear bottleneck* serta *shortcut connection* antar *bottleneck* sebagai bentuk penyempurnaan dari versi sebelumnya (Annur et al., 2023).

2.7 Confusion Matrix

Confusion matrix merupakan tabel evaluasi yang digunakan untuk mengukur kinerja model klasifikasi dengan membandingkan hasil prediksi terhadap label sebenarnya. Tabel ini terdiri dari empat komponen utama, yaitu *True Positive (TP)*, *False Positive (FP)*, *True Negative (TN)*, dan *False Negative (FN)* (Kurniawati et al., 2023).

a. Akurasi

Akurasi merupakan perbandingan antara jumlah prediksi yang benar, baik pada kelas positif maupun negatif, terhadap keseluruhan data yang diuji. Nilai ini menggambarkan seberapa tepat suatu metode dalam mengklasifikasikan data secara benar (Adhitya et al., 2023).

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

b. Precision

Precision adalah metrik evaluasi yang digunakan untuk mengukur tingkat ketepatan model dalam melakukan prediksi data, yaitu seberapa besar proporsi prediksi positif atau *true positive (TP)* yang benar dibandingkan dengan seluruh prediksi positif yang dihasilkan oleh sistem (Sary et al., 2025).

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

c. Recall

Recall adalah metrik yang digunakan untuk mengukur seberapa baik suatu model dalam menemukan semua objek yang seharusnya terdeteksi. Nilai ini menunjukkan berapa banyak objek yang berhasil dikenali dengan benar *true positive (TP)* dibandingkan dengan seluruh objek yang seharusnya dikenali, termasuk yang terlewat *false negative (FN)*. Semakin tinggi nilai recall maka semakin sedikit objek yang terlewat oleh model (Sary et al., 2025).

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

d. F1-Score

F1-score merupakan metrik evaluasi yang menggabungkan nilai *precision* dan *recall* untuk memberikan gambaran kinerja model secara menyeluruh, terutama pada dataset yang tidak seimbang (Hakim et al., 2025).


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

3. METODOLOGI

3.1 Metodologi Penelitian

Metodologi yang digunakan pada penelitian ini adalah metodologi CRISP-DM (*Cross Industry Standard Process for Data Mining*) dengan pendekatan *deep*

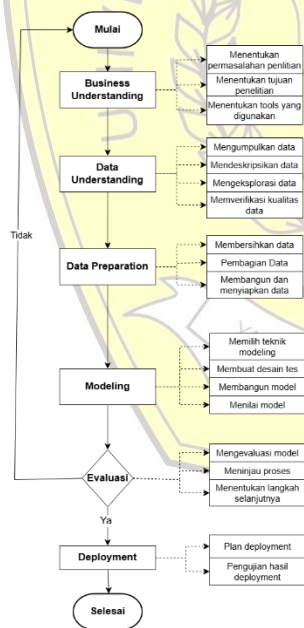
learning menggunakan arsitektur *MobileNetV2* sebagai model utama dalam proses klasifikasi penyakit daun padi. Tahapan yang ditempuh meliputi *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modelling*, *Evaluation*, dan *Deployment*.



Gambar 1. Siklus CRISP-DM

3.2 Rancangan Penelitian

Berikut ini merupakan penjelasan secara garis besar mengenai alur proses dalam penelitian yang akan dilakukan.



Gambar 2. Rancangan Penelitian

4. HASIL DAN PEMBAHASAN

4.1 Hasil Penelitian

4.1.1 Business Understanding

Pada tahap business understanding, diketahui bahwa identifikasi penyakit

tanaman padi masih dilakukan secara manual melalui pengamatan visual. Metode ini berpotensi menimbulkan kesalahan klasifikasi karena beberapa penyakit memiliki gejala yang serupa. Berdasarkan hasil wawancara dengan petani dan Dinas Pertanian Kabupaten Bekasi, belum tersedia sistem yang mampu mengidentifikasi penyakit secara cepat dan akurat. Oleh karena itu, penelitian ini bertujuan mengembangkan model klasifikasi penyakit daun padi menggunakan arsitektur *MobileNetV2* berbasis transfer learning untuk membantu meningkatkan akurasi identifikasi penyakit pada tanaman padi.

4.1.2 Data Understanding

Pada tahap data understanding, dataset diperoleh dari platform Mendeley dan Kaggle yang berisi citra daun padi berbagai kelas penyakit. Berdasarkan hasil analisis dan kebutuhan penelitian, dipilih empat kelas yang digunakan, yaitu Bacterial Leaf Blight, Blast, Healthy, dan not_leaf, dengan total 6.166 citra. Kelas not_leaf ditambahkan untuk membantu model membedakan citra daun padi dan objek selain daun. Selanjutnya dilakukan analisis distribusi data pada setiap kelas serta verifikasi kualitas dataset melalui pengecekan duplikasi citra. Hasil verifikasi menunjukkan terdapat 262 citra duplikat yang kemudian ditangani pada tahap persiapan data.

4.1.3 Data Preparation

Pada tahap data preparation, dilakukan pembersihan dataset dengan menghapus 262 citra duplikat sehingga diperoleh 5.904 citra yang siap digunakan. Selanjutnya, dataset dibagi menjadi data training, validation, dan testing menggunakan dua skenario pembagian, yaitu 80:10:10 dan 75:15:10. Setelah itu, seluruh citra diubah ukurannya menjadi 224×224 piksel dan dinormalisasi menggunakan fungsi `preprocess_input` dari *MobileNetV2*. Untuk meningkatkan variasi data dan kemampuan generalisasi

model, diterapkan teknik augmentasi citra pada data training berupa rotasi, pergeseran, zoom, horizontal flip, serta penyesuaian kecerahan dan kontras.

4.1.4 Modeling

Pada tahap modeling, penelitian ini menggunakan pendekatan transfer learning dengan arsitektur MobileNetV2 yang telah dilatih sebelumnya pada dataset ImageNet. Model dibangun menggunakan TensorFlow dengan input citra berukuran 224x224 piksel.

Model	Skenario Pembagian Data	Optimizer	Metode Training	Epoch
A1	A	Adam	Frozen model	30
A2	A	Adam	Fine-tuning model	30
B1	B	Adam	Frozen model	30
B2	B	Adam	Fine-tuning model	30

Gambar 3. Skenario Pelatihan Model

Proses pelatihan dilakukan menggunakan dua metode, yaitu frozen model dan fine-tuning, serta dua skenario pembagian data, yaitu 80:10:10 dan 75:15:10. Hyperparameter yang digunakan meliputi optimizer Adam, batch size 32, dan 30 epoch untuk setiap skenario pelatihan.

Layer (type)	Output Shape	Param #
mobiletv2_1.00_224 (functional)	(None, 7, 7, 1280)	2,257,984
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
dense (Dense)	(None, 128)	163,968
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 3)	387

Total params: 2,422,339 (9.24 MB)
 Trainable params: 164,355 (642.01 KB)
 Non-trainable params: 2,257,984 (8.61 MB)


Gambar 4. Arsitektur MobilenetV2

Arsitektur model terdiri atas MobileNetV2 sebagai feature extractor dan beberapa layer klasifikasi tambahan berupa Global Average Pooling, Dense layer, Dropout, serta layer output dengan aktivasi Softmax untuk mengklasifikasikan citra ke dalam empat kelas. Pada metode frozen model, seluruh layer MobileNetV2 dibekukan selama proses pelatihan, sedangkan pada metode fine-tuning dilakukan pembukaan 50 layer terakhir untuk meningkatkan kemampuan model dalam mengenali karakteristik penyakit daun padi. Seluruh model

kemudian dilatih dan dievaluasi menggunakan data validasi.

a. Model A1

Model A1 menggunakan skenario pembagian data 80:10:10 dengan metode frozen model. Hasil pelatihan menunjukkan peningkatan akurasi training dan validation yang stabil hingga mencapai akurasi validasi sebesar 96,10% dengan nilai loss 0,1105.




Gambar 5. Grafik Loss dan Akurasi Model A1




Gambar 6. Confusion Matrix Model A1

b. Model A2

Model A2 menggunakan skenario pembagian data 80:10:10 dengan metode fine-tuning. Hasil pelatihan menunjukkan performa yang lebih baik dibandingkan model A1 dengan akurasi validasi mencapai 99,32% dan nilai loss sebesar 0,0330. Hasil confusion matrix menunjukkan sebagian besar data berhasil diklasifikasikan dengan benar pada setiap kelas.




Gambar 7. Grafik Loss dan Akurasi Model A2




Gambar 8. Confusion Matrix Model A2

c. Model B1

Model B1 menggunakan skenario pembagian data 75:15:10 dengan metode frozen model. Model ini menghasilkan akurasi validasi sebesar 95,59% dengan nilai loss 0,1104. Meskipun mampu melakukan klasifikasi dengan baik, jumlah kesalahan klasifikasi masih lebih tinggi dibandingkan model fine-tuning.




Gambar 9. Grafik Loss dan Akurasi Model B1



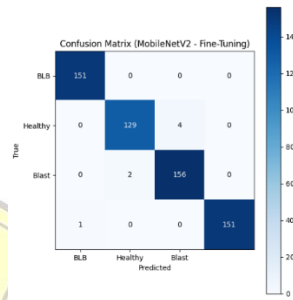
Gambar 10. Confusion Matrix Model B1

d. Model B2

Model B2 menggunakan skenario pembagian data 75:15:10 dengan metode fine-tuning. Hasil pelatihan menunjukkan akurasi validasi sebesar 99,32% dengan nilai loss terendah yaitu 0,0259. Sebagian besar data berhasil diklasifikasikan dengan benar berdasarkan hasil confusion matrix.



Gambar 11. Grafik Loss dan Akurasi Model B2



Gambar 12. Confusion Matrix Model B2

Berdasarkan hasil perbandingan model, A2 dan B2 memperoleh akurasi validasi tertinggi sebesar 99,32%. Namun, model A2 menunjukkan jumlah kesalahan klasifikasi yang lebih sedikit dibandingkan B2, sehingga memiliki performa yang lebih konsisten. Dengan nilai akurasi yang tinggi dan loss yang rendah, model A2 dipilih sebagai model terbaik dan digunakan pada tahap evaluasi selanjutnya.

4.1.5 Evaluasi

Pada tahap evaluasi, performa model diukur menggunakan metrik accuracy, precision, recall, dan F1-score berdasarkan hasil pengujian pada data testing. Model A1 memperoleh akurasi sebesar 97%, dengan nilai precision, recall, dan F1-score berturut-turut sebesar 0,99, 0,98, dan 0,99 untuk kelas Bacterial Leaf Blight; 0,91, 0,98, dan 0,94 untuk kelas Blast; 0,97, 0,92, dan 0,94 untuk kelas Healthy; serta 1,00, 0,99, dan 1,00 untuk kelas not_leaf.

Model A2 memperoleh akurasi sebesar 99%, dengan nilai precision, recall, dan F1-score masing-masing sebesar 0,99, 1,00, dan 1,00 pada kelas Bacterial Leaf Blight; 0,98, 0,98, dan 0,98 pada kelas Blast; 0,99, 0,98, dan 0,98 pada

kelas Healthy; serta 1,00, 0,99, dan 1,00 pada kelas not_leaf.


Sementara itu, model B1 memperoleh akurasi 97%, dengan nilai precision, recall, dan F1-score sebesar 0,99, 0,99, dan 0,99 pada kelas Bacterial Leaf Blight; 0,89, 0,98, dan 0,94 pada kelas Blast; 0,98, 0,90, dan 0,94 pada kelas Healthy; serta 1,00, 0,99, dan 1,00 pada kelas not_leaf.

Model B2 memperoleh akurasi sebesar 99%, dengan nilai precision, recall, dan F1-score sebesar 0,99, 1,00, dan 1,00 pada kelas Bacterial Leaf Blight; 0,98, 0,97, dan 0,98 pada kelas Blast; 0,97, 0,99, dan 0,98 pada kelas Healthy; serta 1,00, 0,99, dan 1,00 pada kelas not_leaf.

Berdasarkan hasil tersebut, model A2 dipilih sebagai model terbaik karena menghasilkan akurasi sebesar 99%, nilai precision, recall, dan F1-score rata-rata sebesar 0,99, serta jumlah kesalahan klasifikasi paling sedikit yaitu 6 data, sehingga menunjukkan kemampuan klasifikasi yang lebih akurat dan konsisten dibandingkan model lainnya.

4.1.6 Deployment

a. Plan Deployment



Gambar 13. Flowchart Plan Deployment

Pada tahap deployment, model terbaik yang telah diperoleh diimplementasikan

ke dalam aplikasi berbasis Streamlit. Aplikasi dikembangkan menggunakan Visual Studio Code (VS Code) dengan memanfaatkan library TensorFlow, NumPy, dan Pillow (PIL). Pengguna dapat mengunggah citra daun padi, kemudian sistem akan melakukan preprocessing dan klasifikasi menggunakan model MobileNetV2. Hasil yang ditampilkan berupa jenis penyakit, nilai confidence, serta rekomendasi penanganan berdasarkan hasil prediksi.

b. Implementasi Sistem



Gambar 14. Tampilan Sistem

Aplikasi dirancang dalam satu halaman sehingga pengguna dapat melakukan proses unggah gambar dan melihat hasil prediksi secara langsung. Hasil yang ditampilkan meliputi jenis penyakit, nilai confidence, serta rekomendasi penanganan berdasarkan hasil klasifikasi model.

c. Pengujian Hasil Deployment

Pengujian deployment dilakukan menggunakan 20 citra baru yang tidak termasuk dalam data training maupun testing untuk mengukur kemampuan model pada kondisi nyata. Data uji terdiri atas 5 citra Bacterial Leaf Blight, 5 citra Blast, 5 citra Healthy, dan 5 citra not_leaf. Hasil pengujian menunjukkan bahwa model berhasil mengklasifikasikan 19 dari 20 citra dengan benar, sehingga memperoleh akurasi sebesar 95%. Kesalahan klasifikasi terjadi pada satu citra kelas Healthy yang diprediksi sebagai Bacterial Leaf Blight. Secara umum, hasil ini menunjukkan bahwa model mampu mempertahankan performa yang baik ketika diimplementasikan pada data baru di luar dataset pelatihan.

4.2 Pembahasan

Penelitian ini telah dilaksanakan mengikuti tahapan CRISP-DM mulai dari business understanding, data understanding, data preparation, modeling, evaluation, hingga deployment. Hasil penelitian menunjukkan bahwa model dengan metode fine-tuning memberikan performa yang lebih baik dibandingkan frozen model. Berdasarkan hasil evaluasi, model A2 dengan skenario pembagian data 80:10:10 memperoleh performa terbaik dengan validation accuracy sebesar 99,32%, akurasi pengujian sebesar 99%, serta jumlah kesalahan klasifikasi paling sedikit yaitu 6 data. Pengujian deployment menggunakan 20 citra baru menghasilkan akurasi sebesar 95%, dengan 19 citra berhasil diklasifikasikan dengan benar. Hasil tersebut menunjukkan bahwa model A2 memiliki kemampuan yang baik dalam mengklasifikasikan penyakit daun padi dan layak digunakan pada kondisi nyata.

5. KESIMPULAN

Berdasarkan hasil penelitian, model klasifikasi penyakit daun padi berbasis MobileNetV2 berhasil dikembangkan dan mampu membantu proses identifikasi penyakit secara otomatis. Model terbaik, yaitu A2 dengan metode fine-tuning dan pembagian data 80:10:10, memperoleh akurasi sebesar 99% pada data testing dan 95% pada data baru. Hasil pengujian juga menunjukkan bahwa metode fine-tuning memberikan performa yang lebih baik dibandingkan frozen model. Selain itu, model A2 memiliki nilai precision, recall, dan F1-score yang tinggi serta jumlah kesalahan klasifikasi paling sedikit, sehingga dipilih sebagai model terbaik dalam penelitian ini.

6. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan, bantuan, dan masukan selama pelaksanaan penelitian ini. Ucapan terima kasih juga disampaikan kepada Dinas

Pertanian Kabupaten Bekasi, para petani di Desa Karangraharja, serta pihak-pihak yang telah membantu dalam proses pengumpulan data dan penyelesaian penelitian ini.

DAFTAR PUSTAKA

- BPS 2024. (2025). Luas Panen dan Produksi Padi Di Indonesia 2024 (Angka Tetap). *Badan Pusat Statistik*, 8(15), 52. <https://www.bps.go.id>
- Pitriana, D., & Haryanto, H. (2025). Evaluation of The Implementation of Integrated Pest Control of Padi (*Oryza sativa*) Farmers in The P4 Program in District West Lombok Dewi. *Jurnal Ilmiah Mahasiswa AGROKOMPLEK*, 4(1), 146–154.
- Nurhaliza, & Suendri. (2025). Journal of Dinda. *Journal.Ittelkom-Pwt.Ac.Id/Index.Php/Dinda*, 5(2), 258–267.
- Sutiharni; Sembiring, Jefri; Sari, Permata Silvia; Meilin, Araz; Oktaviani; Sidik, Alfiani Effi; Decenly; Ratih, Suskandini; Anwar; Afifah, L. (2024). *Pengendalian Hama dan Penyakit Tanaman* (M. Sari, Ed.). CV GETPRESS INDONESIA.
- Adhitya, R. R., Wina Witanti, & Rezki Yuniarti. (2023). Perbandingan Metode Cart Dan Naïve Bayes Untuk Klasifikasi Customer Churn. *INFOTECH Journal*, 9(2), 307–318. <https://doi.org/10.31949/infotech.v9i2.5641>
- Roeswitawati, Dyah; Sukorini, H. (2023). *Penyakit tumbuhan* (Number December). Universitas Muhammadiyah Malang.
- Laraswati, R., Ramdan, E. P., & Kulsum, U. (2021). Identifikasi penyebab penyakit hawar daun bakteri pada kombinasi pola. *Jurnal Produksi Pertanian*, 15(2), 4026–4051.
- Sudir, Nuryanto, B., & Kadir, T. S. (2022). Epidemiologi, Patotipe, dan Strategi Pengendalian Penyakit Hawar Daun Bakteri pada Tanaman Padi. *Iptek*

- Tanaman Pangan*, 7(2), 79–87.
- Distankan. (2025). *Penyakit Hawar Daun Bakteri pada Tanaman Padi*. Distankan.Bulelengkab.Go.Id. https://distankan.bulelengkab.go.id/info-rmasi/detail/artikel/55_penyakit-hawar-daun-bakteri-pada-tanaman-padi
- Silfia, D. E. (2023). *Inventarisasi Jamur Penyebab Penyakit Pada Daun Padi (Oryza Sativa) Pada Fase Generatif Di Kabupaten Pesawaran*. 1–89.
- BPTP, B. (2022). *Teknologi Pengendalian Penyakit Blast. BPTP Banten*. <https://repository.pertanian.go.id/items/0cab7956-fba2-4fb4-a501-58abac369bc3>
- Sastya, N. C., & Nugraha, I. (2023). Penerapan Metode CRISP-DM dalam Menganalisis Data untuk Menentukan Customer Behavior di MeatSolution. *Unistek*, 10(2), 103–115. <https://doi.org/10.33592/unistek.v10i2.3079>
- Setiawan, F. B., Aldo Wijaya, O. J., Pratomo, L. H., & Riyadi, S. (2021). Sistem Navigasi Automated Guided Vehicle Berbasis Computer Vision dan Implementasi pada Raspberry Pi. *Jurnal Rekayasa Elektrika*, 17(1), 7–14. <https://doi.org/10.17529/jre.v17i1.18087>
- Faturrahman, R., Hariyani, Y. S., & Hadiyoso, S. (2023). Klasifikasi Jajanan Tradisional Indonesia berbasis Deep Learning dan Metode Transfer Learning. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(4), 945. <https://doi.org/10.26760/elkomika.v11i4.945>
- Annur, I. F., Umami, J., Annafii, M. N., Trisnaningrum, N., & Putra, O. V. (2023). Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetv2. *Fountain of Informatics Journal*, 8(1), 7–14. <https://doi.org/10.21111/fij.v8i1.9419>
- Kurniawati, F., & Brahma Arianto, D. (2023). Analisis Implementasi Seleksi Fitur Pada Klasifikasi Diabetes dengan Metode Corellation Matrix dan Algoritma Logistic Regression. *Informatik: Jurnal Ilmu Komputer*, 19(3), 157–164. <https://doi.org/10.52958/iftk.v19i3.6019>
- Lizard Sambawo Dimara, D., Rahmat, B., & Maulana, H. (2025). Identifikasi Penyakit Daun Padi Dengan Metode Transfer Learning Mobilenet - Support Vector Machine. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(3), 5413–5420. <https://doi.org/10.36040/jati.v9i3.14245>
- Putra, O. V., Mustaqim, M. Z., & Muriatmoko, D. (2023). Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2. *Techno.Com*, 22(3), 562–575. <https://doi.org/10.33633/tc.v22i3.8516>
- Velarati, K., Sari, C. A., & Rachmawanto, E. H. (2024). A Comparison of Convolutional Neural Network (CNN) and Transfer Learning MobileNetV2 Performance on Spices Images Classification. *Journal of Applied Informatics and Computing*, 8(2), 413–420. <https://doi.org/10.30871/jaic.v8i2.86227>
- Hakim, L., Sobri, A., Sunardi, L., & Nurdiansyah, D. (2025). Prediksi penyakit jantung berbasis mesin learning dengan menggunakan metode k-nn. *Jurnal Digital Teknologi Informasi*, 7(2), 14. <https://doi.org/10.32502/digital.v7i2.9429>