

Klasifikasi Penyakit Daun Padi Berbasis Website Menggunakan CNN EfficientNet-B0

W. Ghifari¹, H. Ardiansyah²

^{1,2} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang,
Tangerang Selatan, Banten

e-mail: wildan.wuzhou@gmail.com, dosen00832@unpam.ac.id

Abstrak

Penyakit daun padi seperti Bacterial Blight, Blast, Brownspot, dan Tungro menjadi ancaman yang menurunkan produktivitas panen di wilayah Pertanian RW 002, Kecamatan Sumpiuh, Kabupaten Banyumas. Identifikasi penyakit secara manual oleh pengawas lapangan berjalan lambat dan rentan salah akibat kemiripan visual antar gejala, terutama bagi petani baru yang harus menunggu respons pengawas. Penelitian ini merancang dan mengimplementasikan sistem klasifikasi otomatis berbasis website yang memberikan indikasi awal secara cepat kepada petani, tanpa menggantikan peran pengawas sebagai pengambil keputusan akhir. Convolutional Neural Network dengan arsitektur EfficientNet-B0 diimplementasikan menggunakan PyTorch dan pustaka timm, dilatih pada dataset gabungan dari repositori publik Kaggle. Sistem dibangun menggunakan framework Flask dan basis data MySQL mengikuti pendekatan Software Development Life Cycle. Pengujian pada data uji Kaggle menunjukkan model mencapai akurasi, presisi, dan recall sebesar 99%, sementara pengujian Black Box dan White Box membuktikan website memproses citra unggahan dan menampilkan hasil klasifikasi secara responsif. Namun, pengujian tambahan pada citra lapangan asli menunjukkan penurunan akurasi yang signifikan, mengindikasikan domain gap antara data latih dan kondisi lapangan. Temuan ini menjadi dasar disediakannya mekanisme verifikasi pengawas, sehingga hasil otomatis tetap dapat ditinjau dan dikoreksi tanpa mengambil alih keputusan akhir dari pengawas lapangan.

Kata Kunci: Padi, Penyakit Daun, CNN, EfficientNet-B0, Website

Abstract

Rice leaf diseases such as Bacterial Blight, Blast, Brownspot, and Tungro threaten harvest productivity in the Pertanian RW 002 area, Sumpiuh District, Banyumas Regency. Manual disease identification by field supervisors is slow and error-prone due to visual mimicry between symptoms, a problem especially felt by inexperienced farmers awaiting the supervisor response. This study designs and implements a website-based automatic classification system that gives farmers a fast initial indication without replacing the supervisor as final decision-maker. A Convolutional Neural Network with the EfficientNet-B0 architecture was implemented using PyTorch and the timm library, trained on a combined dataset from the public Kaggle repository, with the system built using Flask and a MySQL database following the Software Development Life Cycle approach. Testing on the Kaggle test set shows the model reaches an accuracy, precision, and recall of 99%, while Black Box and White Box testing confirm the website processes uploaded images and displays results responsively. However, testing on field images shows a marked drop in accuracy, indicating a domain gap between training data and real field conditions, which justifies the built-in supervisor verification mechanism so every automatic result can still be reviewed and corrected.

Keywords : *Rice, Leaf Disease, CNN, EfficientNet-B0, Website*

LATAR BELAKANG

Padi (*Oryza sativa* L.) adalah komoditas pangan strategis di Indonesia, dan Kabupaten Banyumas merupakan salah satu penyumbang produksi beras regional di Jawa Tengah dengan capaian 375.511 ton pada tahun 2024 (Hermiana, 2024). Meskipun demikian, pertanian padi di Kecamatan Sumpiuh, khususnya di wilayah RW 002, terus menghadapi ancaman serangan penyakit daun, yaitu Bacterial Blight, Blast, Brownspot, dan Tungro. Bacterial Blight dilaporkan dapat menurunkan hasil panen hingga 70-80% (Erwin, 2024), sedangkan Brownspot dapat menurunkan produktivitas hingga 45% dan mengurangi kuantitas gabah secara signifikan (Norjamilah, Mariana, & Budi, 2021), dan Tungro maupun Blast secara konsisten mengancam keberhasilan panen melalui infeksi pada daun dan malai (Dinas Pertanian Buleleng, 2020, 2022).

Selama ini identifikasi penyakit di lapangan masih bergantung pada observasi visual manual oleh pengawas: petani memotret daun yang terindikasi sakit dan menunggu tanggapan pengawas, sebuah proses yang sering memakan waktu karena keterbatasan jumlah tenaga penyuluh dan luasnya wilayah dampingan. Kondisi ini terasa lebih berat bagi petani baru yang belum terbiasa mengenali gejala secara mandiri. Di sisi lain, fenomena kemiripan visual (mimicry) antar gejala turut meningkatkan risiko salah diagnosis, misalnya antara daun menguning akibat Tungro dengan gejala serupa pada Bacterial Blight, atau antara bercak Brownspot dengan Blast. Kesalahan identifikasi ini berpotensi mendorong penggunaan pestisida atau fungisida yang tidak tepat sasaran, sehingga meningkatkan biaya produksi tanpa menyelesaikan masalah.

Perkembangan deep learning, khususnya Convolutional Neural Network (CNN), menawarkan solusi untuk mengekstraksi fitur visual kompleks pada citra daun secara otomatis dan telah banyak diterapkan pada klasifikasi penyakit daun padi dengan akurasi tinggi (Julianto, Sunyoto, & Wibowo, 2022; Khoiruddin, Junaidi, & Saputra, 2022; Hu et al., 2025). Akan tetapi, hasil-hasil tersebut umumnya berhenti pada tahap pengujian model di lingkungan komputasi dan belum diwujudkan menjadi platform yang dapat langsung diakses oleh petani awam di lapangan, khususnya di Kabupaten Banyumas.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan merancang dan mengimplementasikan sistem klasifikasi penyakit daun padi berbasis website menggunakan CNN dengan arsitektur EfficientNet-B0, yang dipilih karena keseimbangan antara akurasi dan efisiensi komputasi melalui pendekatan compound scaling (Tan & Le, 2019) sehingga sesuai untuk memberikan hasil secara cepat pada aplikasi web. Sistem dirancang sebagai mekanisme respons awal (first response) yang dapat diakses tanpa proses masuk (login), dilengkapi fitur verifikasi berjenjang oleh pengawas agar hasil deteksi otomatis tetap dapat ditinjau dan dikoreksi sebelum menjadi dasar penanganan akhir.

Berdasarkan uraian tersebut, rumusan masalah yang diangkat dalam penelitian ini adalah: bagaimana merancang model CNN dengan arsitektur EfficientNet-B0 yang mampu mengklasifikasikan empat jenis penyakit daun padi secara akurat, serta bagaimana mengimplementasikan model tersebut ke dalam sistem berbasis website yang dapat diakses secara mudah oleh petani tanpa mengurangi peran penting pengawas lapangan sebagai pemegang keputusan akhir dalam penanganan penyakit tanaman.

Secara spesifik, penelitian ini bertujuan untuk: (1) mengimplementasikan CNN sebagai mesin klasifikasi otomatis yang objektif dan terukur untuk empat kelas penyakit daun padi; (2) menganalisis efektivitas ekstraksi fitur arsitektur EfficientNet-B0 dalam membedakan gejala penyakit yang memiliki kemiripan visual; (3) merancang mekanisme respons awal yang cepat bagi petani namun tetap dilengkapi jalur verifikasi dan koreksi oleh pengawas; dan (4) menyediakan sistem informasi berbasis website yang fungsional dan responsif sebagai media bantu deteksi mandiri bagi petani di wilayah RW 002, Kecamatan Sumpiuh.

Bagi petani, khususnya petani baru atau yang belum berpengalaman, sistem ini diharapkan menjadi jembatan awal sebelum memperoleh verifikasi dari pengawas sehingga tidak perlu menunggu lama untuk mendapatkan respons, sekaligus menekan risiko

kesalahan penanganan seperti penggunaan pestisida atau fungisida yang tidak tepat sasaran akibat salah diagnosis. Bagi pengawas lapangan, mekanisme verifikasi berjenjang yang disediakan sistem membantu mengurangi ketergantungan penuh pada pelaporan manual satu per satu, karena riwayat deteksi otomatis dapat ditinjau dan dikoreksi secara terpusat melalui dasbor pengawas.

Penelitian Relevan

Beberapa penelitian terdahulu yang relevan dengan konsep penelitian ini ditinjau sebagai acuan dalam mengembangkan hasil penelitian sebelumnya.

Julianto, Sunyoto, dan Wibowo (2022) mengoptimasi hyperparameter CNN MobileNet-V2 untuk tiga kelas penyakit daun padi (blast, blight, tungro) dan mencapai akurasi 97,56%, presisi 97,64%, serta recall 97,57%. Khoiruddin, Junaidi, dan Saputra (2022) menerapkan CNN untuk mengklasifikasikan tiga jenis penyakit daun padi (Bacterial leaf blight, Rice blast, Rice tungro virus) dari 6.000 citra dengan akurasi 98% pada epoch ke-100. Hu et al. (2025) mengusulkan model DepMulti-Net untuk empat kelas penyakit yang sama dengan penelitian ini dan mencapai akurasi rata-rata 98,56%. Rustanto, Liantoni, dan Prakisy (2024) menggunakan ekstraksi fitur Gray Level Co-occurrence Matrix (GLCM) dengan klasifikasi K-Nearest Neighbor (KNN) untuk tiga jenis penyakit daun padi dan hanya memperoleh akurasi 73%, jauh di bawah pendekatan deep learning. Yuliany, Aradea, dan Rachman (2022) mengimplementasikan CNN untuk klasifikasi hama padi dan menyoroti pentingnya rasio pembagian data latih-uji terhadap risiko overfitting, dengan rasio 90:10 menghasilkan akurasi pengujian 77,33%. Pada domain yang berdekatan, Soekarta, Nurdjan, dan Syah (2023) membangun sistem klasifikasi penyakit tanaman tomat berbasis CNN VGG16 yang diintegrasikan ke dalam sistem website dengan akurasi latih 98% dan akurasi validasi 82%, menunjukkan bahwa integrasi model deep learning ke antarmuka web merupakan pendekatan yang layak diterapkan pada domain pertanian.

Perbandingan keenam penelitian relevan tersebut dengan penelitian ini dirangkum pada Tabel 1.

Tabel 1. Perbandingan Penelitian Relevan

Peneliti (Tahun)	Metode	Akurasi	Perbedaan dengan Penelitian Ini
Julianto dkk. (2022)	Optimasi hyperparameter MobileNet-V2, 3 kelas	97,56%	Penelitian ini memakai EfficientNet-B0, 4 kelas, dan sistem website lengkap
Khoiruddin dkk. (2022)	CNN, 3 kelas	98%	Menambahkan riwayat scan dan dasbor verifikasi pengawas
Hu dkk. (2025)	DepMulti-Net, 4 kelas	98,56%	Model diintegrasikan langsung ke sistem website dengan verifikasi pengawas
Rustanto dkk. (2024)	GLCM + KNN	73%	Menggunakan pendekatan deep learning (CNN) tanpa ekstraksi fitur manual
Yuliany dkk. (2022)	CNN untuk hama padi	77,33%	Berfokus pada klasifikasi penyakit, bukan hama, dengan EfficientNet-B0
Soekarta dkk. (2023)	CNN VGG16, tanaman tomat	98% (latih)	Berfokus pada objek tanaman padi dengan arsitektur yang lebih ringan

Berdasarkan perbandingan tersebut, metode berbasis CNN secara konsisten menghasilkan akurasi lebih tinggi dibandingkan metode ekstraksi fitur konvensional seperti GLCM-KNN. Oleh karena itu, penelitian ini memilih pendekatan CNN dengan arsitektur EfficientNet-B0 karena efisien secara komputasi namun tetap kompetitif secara akurasi

dibandingkan arsitektur CNN lain seperti VGG16 atau MobileNet-V2. Berbeda dengan penelitian-penelitian relevan di atas yang umumnya berhenti pada tahap pengujian model, penelitian ini mengimplementasikan model ke dalam sistem berbasis website yang lengkap dengan mekanisme verifikasi berjenjang oleh pengawas lapangan.

METODE

Penelitian ini mengadopsi beberapa metode pengumpulan data secara beriringan. Metode observasi dilakukan dengan pengamatan langsung di area Pertanian RW 002, Kecamatan Sumpiuh, untuk melihat kondisi fisik tanaman padi yang terserang penyakit serta mengambil sampel citra daun padi secara langsung yang digunakan sebagai data uji validasi tambahan. Metode wawancara dilakukan melalui sesi tanya jawab dengan petani dan pengurus kelompok tani setempat untuk menggali kendala identifikasi penyakit secara manual, fenomena kemiripan gejala yang kerap mengecoh petani, serta kebutuhan sistem alat bantu yang diharapkan. Studi literatur dilakukan dengan mengumpulkan landasan teori dari jurnal, buku, dan publikasi ilmiah terkait CNN dan patologi tanaman, sekaligus menjadi dasar pengunduhan dataset sekunder dari repositori publik Kaggle untuk kebutuhan pelatihan model.

Dataset dan Pra-pemrosesan Data

Dataset citra daun padi bersumber dari repositori publik Kaggle (nimalsankalana/rice-leaf-disease-image) dengan empat kelas: Bacterial Blight, Blast, Brownspot, dan Tungro. Sebelum pelatihan, dilakukan pembersihan data duplikat menggunakan metode perceptual hashing (ImageHash) untuk mencegah kebocoran data (data leakage) yang berpotensi menimbulkan overfitting; proses ini menemukan bahwa lebih dari separuh data mentah merupakan citra duplikat atau hampir identik. Dataset kemudian dibagi menggunakan metode stratified split menjadi 80% data latih (15% di antaranya disisihkan sebagai data validasi) dan 20% data uji.

Citra diubah ukurannya secara bertahap menjadi 256x256 piksel lalu dipotong acak (random crop) menjadi 224x224 piksel sesuai standar masukan EfficientNet. Augmentasi tambahan diterapkan untuk mensimulasikan kondisi foto lapangan, meliputi rotasi acak hingga 45°, pembalikan horizontal/vertikal, pergeseran posisi (random affine), variasi pencahayaan dan warna (color jitter), efek buram (Gaussian blur), serta random erasing dengan probabilitas 0,2.

Setiap citra diverifikasi dan diberi label ke dalam salah satu dari empat kelas penyakit, kemudian label teks tersebut diubah menjadi bentuk numerik (label encoding) agar dapat diproses oleh model CNN. Pembagian dataset menggunakan metode stratified split dipilih agar proporsi keempat kelas tetap seimbang pada data latih, data validasi, maupun data uji, sehingga proses pelatihan, validasi, dan evaluasi model dapat dilakukan secara terukur dan adil terhadap seluruh kelas.

Arsitektur Model CNN EfficientNet-B0

CNN adalah pengembangan neural network yang menambahkan convolutional layer dan pooling layer untuk mengekstraksi pola fitur citra secara hierarkis, mulai dari tepi dan tekstur sederhana hingga pola kompleks, sebelum diklasifikasikan pada fully connected layer (Yang, 2021). Pemilihan metode pooling turut memengaruhi efisiensi ekstraksi fitur tanpa mengurangi akurasi model (Zafar et al., 2022), sementara fungsi aktivasi non-linear seperti ReLU berperan penting mengatasi masalah vanishing gradient dan mempercepat konvergensi pelatihan (Mesran, Yahya, Nugroho, & Windarto, 2024). EfficientNet-B0 yang digunakan dalam penelitian ini menerapkan metode compound scaling yang menyeimbangkan kedalaman (depth), lebar (width), dan resolusi (resolution) jaringan secara serempak, dengan blok pembangun dasar MBConv (Mobile Inverted Bottleneck Convolution) yang diperkuat mekanisme Squeeze-and-Excitation untuk memusatkan perhatian model pada fitur visual yang paling relevan, seperti pola bercak dan warna gejala penyakit (Tan & Le, 2019). Dibandingkan model konvensional yang lebih besar, EfficientNet-B0 mempertahankan akurasi tinggi dengan jumlah parameter yang jauh lebih ringkas, sehingga

cocok memberikan hasil diagnosis secara cepat (low latency) saat diintegrasikan ke server web (Aria, Slamet, & Firdaus, 2025).

Parameter Pelatihan

Pelatihan model dilakukan pada lingkungan Google Colab berakselerasi GPU menggunakan Python, PyTorch, dan pustaka timm. Rincian hyperparameter yang digunakan ditunjukkan pada Tabel 2.


Tabel 2. Parameter Pelatihan Model	
Parameter	Nilai
Arsitektur	EfficientNet-B0
Jumlah kelas	4
Optimizer	AdamW
Loss function	CrossEntropyLoss
Learning rate	0,0001 (1e-4)
Weight decay	0,0001 (1e-4)
Batch size	32
Dropout rate	0,3
Jumlah epoch	15
Resolusi input	224x224 piksel

Penelitian ini dibatasi pada klasifikasi empat jenis penyakit daun padi yang tersedia pada dataset (Bacterial Blight, Blast, Brownspot, dan Tungro) menggunakan data citra digital format JPG/JPEG/PNG dengan pencahayaan yang cukup. Proses preprocessing dan augmentasi dibatasi pada operasi dasar (resizing, normalization, rotation, flipping, color jitter) tanpa segmentasi objek. Pengujian model hanya mencakup metrik performa utama (accuracy, precision, recall, F1-Score) tanpa metrik efisiensi komputasi seperti latency atau compression rate, dan sistem dievaluasi terhadap citra statis, bukan input kamera secara real-time.

Tabel 3. Spesifikasi Perangkat Keras dan Perangkat Lunak	
Komponen	Spesifikasi
Prosesor (pelatihan)	GPU cloud Google Colab (NVIDIA T4)
Bahasa pemrograman	Python 3
Framework deep learning	PyTorch + timm (PyTorch Image Models)
Framework web	Flask
Basis data	MySQL
Antarmuka	HTML, CSS, JavaScript (responsif)

Perancangan Basis Data

Struktur basis data dirancang menggunakan Entity Relationship Diagram (ERD) yang kemudian ditransformasikan ke Logical Record Structure (LRS) untuk mempermudah implementasi tabel relasional (Pulungan, Febrianti, Lestari, Gurning, & Fitriana, 2023), seperti ditunjukkan pada Gambar 1. Entitas utama pada basis data MySQL mencakup tabel users (akun pengawas), diseases (master data empat kelas penyakit beserta deskripsi dan solusi penanganan), serta scans (riwayat pemindaian yang menyimpan berkas citra, hasil kelas prediksi, nilai confidence, dan status koreksi pengawas). Relasi antara tabel scans dan diseases bersifat many-to-one, sedangkan tabel users terhubung dengan scans melalui aktivitas koreksi yang dilakukan pengawas.




Gambar 1. Entity Relationship Diagram (ERD) Sistem

Perancangan Sistem

Sistem usulan dirancang agar petani dapat langsung mengunggah foto daun padi tanpa proses login. Model CNN EfficientNet-B0 memproses citra tersebut dan menampilkan hasil klasifikasi beserta tingkat kepercayaan (confidence) dan rekomendasi penanganan awal. Pengawas memiliki akses terpisah untuk memantau seluruh riwayat deteksi dan dapat melakukan intervensi berupa catatan atau koreksi label apabila prediksi sistem dinilai kurang tepat, sehingga terbentuk mekanisme verifikasi berjenjang antara sistem otomatis dan keahlian pengawas lapangan, seperti diilustrasikan pada Gambar 2.


Pengembangan perangkat lunak mengikuti pendekatan Software Development Life Cycle (SDLC), yaitu proses sistematis untuk mengembangkan perangkat lunak secara terstruktur agar hasil akhirnya memenuhi kebutuhan pengguna, berkualitas, dan dapat diandalkan dalam jangka panjang. Tahap perencanaan menentukan tujuan proyek dan kebutuhan sistem; tahap analisis mengidentifikasi kebutuhan pengguna (petani dan pengawas) serta menetapkan spesifikasi fitur; tahap desain merancang arsitektur sistem, antarmuka pengguna, dan struktur basis data; tahap implementasi menerjemahkan rancangan menjadi kode program menggunakan framework Flask dengan basis data MySQL; dan tahap pengujian memverifikasi bahwa seluruh fitur berfungsi sesuai rancangan sebelum sistem digunakan.




Gambar 2. Alur Kerja Sistem Usulan

Implementasi Antarmuka

Antarmuka petani dirancang minimal agar dapat langsung digunakan tanpa proses masuk (login): pengguna membuka halaman deteksi, mengunggah foto daun padi, lalu menerima hasil klasifikasi beserta persentase confidence dan rekomendasi penanganan awal secara instan (Gambar 3), dengan riwayat pemindaian disimpan secara lokal (LocalStorage) di perangkat petani. Panel pengawas menyediakan dasbor terpisah yang menampilkan ringkasan aktivitas deteksi serta menu pengelolaan riwayat pemindaian dan basis data solusi penanganan penyakit (Gambar 4), sehingga pengawas dapat meninjau, memberi catatan, atau mengoreksi label hasil klasifikasi otomatis kapan pun diperlukan.



Gambar 3. Halaman Deteksi Penyakit bagi Petani



Gambar 4. Dasbor Pengawas

Evaluasi Model

Kinerja model dievaluasi menggunakan confusion matrix yang membandingkan kelas prediksi dengan kelas sebenarnya pada data uji, dengan tiga metrik utama: presisi (Precision), yang mengukur keakuratan prediksi positif; recall, yang menilai kemampuan model mengenali seluruh kasus positif; serta F1-Score sebagai rata-rata harmonis keduanya. Ketiga metrik dihitung menggunakan Persamaan (1) sampai (3), dengan TP = true positive, FP = false positive, FN = false negative:

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

Persamaan (1) merupakan rumus Precision, Persamaan (2) merupakan rumus Recall, dan Persamaan (3) merupakan rumus F1-Score.

Pengujian Sistem

Fungsionalitas perangkat lunak diuji menggunakan metode Black Box pada seluruh fitur utama (login pengawas, deteksi penyakit, riwayat deteksi petani, pengelolaan riwayat oleh pengawas, dan pengelolaan solusi penanganan) untuk memastikan kesesuaian antara masukan dan keluaran sistem. Selain itu, pengujian White Box dilakukan pada fungsi inti login dan deteksi penyakit dengan menghitung cyclomatic complexity menggunakan Persamaan (4), guna memastikan seluruh jalur logika program (basis path) telah teruji.


$$V(G) = E - N + 2 \quad (4)$$

dengan E adalah jumlah edge dan N adalah jumlah node pada flowgraph masing-masing fungsi.

HASIL DAN PEMBAHASAN

Hasil Pelatihan Model


Selama 15 epoch pelatihan, akurasi latih dan validasi meningkat tajam pada empat epoch pertama, kemudian stabil setelah epoch kelima dan menembus angka di atas 0,95, dengan kurva validasi yang menempel ketat pada kurva pelatihan sehingga mengindikasikan generalisasi yang baik tanpa overfitting (Gambar 5). Nilai loss yang semula sekitar 1,8 menurun eksponensial dan melandai stabil di bawah 0,25 pada epoch ke-10 hingga ke-15, mengonfirmasi konvergensi model yang optimal. Pola kurva accuracy dan loss yang stabil sejak pertengahan pelatihan juga mengindikasikan bahwa kombinasi learning rate 0,0001 dan strategi augmentasi yang diterapkan sudah memadai untuk mencegah model berhenti pada local minimum yang buruk, tanpa memerlukan teknik tambahan seperti learning rate scheduling maupun early stopping pada rentang 15 epoch yang diujikan.



Gambar 5. Grafik Accuracy dan Loss Selama Pelatihan

Evaluasi Confusion Matrix

Hasil confusion matrix pada data uji ditunjukkan pada Gambar 6.



Gambar 6. Visualisasi Confusion Matrix

Tabel 4. Precision, Recall, dan F1-Score per Kelas

Kelas	Precision	Recall	F1-Score
Bacterial Blight	0,9912	0,9825	0,9868
Blast	0,9815	0,9725	0,9770
Brownspot	0,9870	1,0000	0,9935
Tungro	1,0000	1,0000	1,0000

Berdasarkan Tabel 4, model menghasilkan nilai precision, recall, dan F1-Score antara 0,97 hingga 1,00 untuk seluruh kelas, dengan kelas Tungro dan Brownspot menunjukkan pemisahan yang paling bersih dari kelas lain. Sedikit kesalahan klasifikasi terjadi antara kelas Bacterial Blight dan Blast, yang secara teori memang memiliki kemiripan visual (mimicry) pada tahap awal infeksi.

Hasil Pengujian Sistem

Pengujian Black Box pada seluruh fitur utama—login pengawas, deteksi penyakit, riwayat deteksi petani, pengelolaan riwayat oleh pengawas, dan pengelolaan solusi penanganan—menunjukkan bahwa keluaran sistem sesuai dengan skenario data benar maupun data salah yang diujikan, sehingga seluruh fitur dinyatakan diterima, sebagaimana dirangkum pada Tabel 5.

Tabel 5. Rekapitulasi Hasil Pengujian Black Box

Fitur yang Diuji	Skenario	Kesimpulan
Login pengawas	Kredensial benar/salah	Diterima
Deteksi penyakit	File valid/tidak valid, confidence rendah	Diterima
Riwayat saya (petani)	Penyimpanan & tampilan riwayat lokal	Diterima
Kelola riwayat (pengawas)	Tinjau, koreksi label hasil deteksi	Diterima
Kelola solusi penanganan	Tambah/ubah data master solusi	Diterima

Pengujian White Box pada fungsi login menghasilkan cyclomatic complexity $V(G) = 3$ dengan tiga jalur independen, sedangkan fungsi deteksi penyakit menghasilkan $V(G) = 4$ dengan empat jalur independen yang mencakup skenario file tidak diunggah, nama file kosong, confidence di bawah ambang 60% (dinyatakan tidak dikenali), dan prediksi berhasil disimpan ke riwayat. Kedua fungsi inti dinyatakan valid karena jumlah jalur uji sesuai dengan nilai $V(G)$ yang dihitung, sehingga seluruh jalur logika program (basis path) pada kedua fungsi tersebut telah teruji.

PEMBAHASAN

Dibandingkan dengan penelitian sejenis, model EfficientNet-B0 yang diusulkan menunjukkan hasil yang kompetitif pada pengujian data uji bersumber Kaggle, sebagaimana dirangkum pada Tabel 6.

Tabel 6. Perbandingan dengan Penelitian Terdahulu

Penelitian	Metode	Akurasi
Julianto dkk. (2022)	MobileNet-V2 (3 kelas)	97,56%
Khoiruddin dkk. (2022)	CNN (3 kelas)	98%
Hu dkk. (2025)	DepMulti-Net (4 kelas)	98,56%
Rahman dkk. (2024)	ResNet-50	97%
Penelitian ini	EfficientNet-B0 (4 kelas)	99%

Perbandingan tersebut menunjukkan bahwa arsitektur EfficientNet-B0 mampu bersaing dengan model CNN lain yang lebih umum digunakan pada klasifikasi penyakit daun padi, sekaligus tetap ringkas untuk diintegrasikan ke server web. Meskipun demikian, mayoritas penelitian pembandingan di atas juga melakukan pengujian pada data uji yang bersumber dari domain data latih yang sama (dataset publik), sehingga belum tentu mencerminkan performa pada kondisi lapangan sesungguhnya. Temuan penelitian ini yang menunjukkan penurunan akurasi ke kisaran 50% pada citra lapangan asli memperkuat pentingnya validasi lapangan sebagai bagian dari evaluasi model klasifikasi penyakit tanaman, bukan hanya mengandalkan metrik pada test split dari sumber data yang sama.

Dataset Kaggle yang digunakan cenderung seragam dari segi pencahayaan, latar belakang, dan sudut pengambilan gambar, sehingga model berisiko mempelajari pola spesifik dataset tersebut (misalnya warna latar atau pencahayaan studio), bukan semata ciri visual penyakit yang bersifat umum di lapangan—fenomena yang dikenal sebagai domain gap. Temuan ini menjadi justifikasi utama disediakannya fitur verifikasi dan koreksi oleh pengawas dalam sistem, sehingga keterbatasan akurasi model pada kondisi lapangan nyata

tetap dapat dimitigasi melalui mekanisme verifikasi berjenjang, tanpa mengorbankan kecepatan respons awal yang diterima petani.

Secara praktis, temuan ini menunjukkan bahwa sistem sebaiknya diposisikan sebagai alat bantu pendukung keputusan (decision support tool) dan bukan sebagai pengganti penuh peran pengawas lapangan. Confidence score yang ditampilkan pada setiap hasil klasifikasi memberikan transparansi kepada petani mengenai tingkat keyakinan model, sementara mekanisme koreksi oleh pengawas memastikan setiap kasus yang meragukan tetap mendapatkan penilaian ahli sebelum penanganan diterapkan di lapangan, sejalan dengan prinsip explainable dan human-in-the-loop pada penerapan machine learning untuk pengambilan keputusan kritis (Wiggerthale & Reich, 2024).

SIMPULAN

CNN dengan arsitektur EfficientNet-B0 berhasil diimplementasikan sebagai mesin klasifikasi otomatis empat penyakit daun padi (Bacterial Blight, Blast, Brownspot, Tungro) yang terintegrasi penuh ke dalam sistem berbasis website menggunakan Flask dan basis data MySQL, dengan nilai precision, recall, dan F1-Score pada data uji Kaggle berkisar 0,97-1,00. Sistem menyediakan mekanisme respons awal yang dapat diakses tanpa login bagi petani, dilengkapi fitur verifikasi berjenjang oleh pengawas yang terbukti penting mengingat ditemukannya domain gap antara data latih dan kondisi lapangan asli. Pengujian Black Box pada seluruh fitur utama dan pengujian White Box pada fungsi inti (login dan deteksi penyakit) menunjukkan sistem berfungsi sesuai rancangan dengan seluruh jalur logika program teruji, sehingga sistem ini dapat digunakan sebagai media bantu deteksi mandiri yang fungsional dan responsif bagi petani di wilayah RW 002, Kecamatan Sumpiuh. Penelitian selanjutnya disarankan menghimpun citra lapangan tambahan untuk fine-tuning model, membentuk test set murni dari data lapangan, serta mempertimbangkan segmentasi daun sebagai pra-pemrosesan tambahan guna menutup domain gap yang ditemukan.

DAFTAR PUSTAKA

- Aria, M. S. A., Slamet, C., & Firdaus, M. D. 2025. Klasifikasi Fake Dan Real Menggunakan Vision Transformer Dan Efficientnet-B0 Pada Gambar Asli Dan Generatif AI. *SMATIKA JURNAL*, 15(01), 179-192. <https://doi.org/10.32664/Smatika.V15i01.1531>
- Dinas Pertanian Buleleng. 2020. *Mengenal Penyakit Tungro Pada Padi Dan Cara Mengatasinya*. https://distan.bulelengkab.go.id/informasi/detail/artikel/34_Mengenal-Penyakit-Tungro-Pada-Padi-Dan-Cara-Mengatasinya
- Dinas Pertanian Buleleng. 2022. *Penyakit Blas (Pyricularia Oryzae) Pada Tanaman Padi*. https://distan.bulelengkab.go.id/informasi/detail/artikel/85_Penyakit-Blas-Pyricularia-Oryzae-Pada-Tanaman-Padi
- Erwin. 2024. *Evaluasi Faktor-Faktor Yang Mempengaruhi Tingkat Serangan Penyakit Hawar Daun Bakteri (Xanthomonas Oryzae Pv. Oryzae) Pada Tanaman Padi Di Kabupaten Sidenreng Rappang* [Skripsi, Universitas Hasanuddin]. <https://repository.unhas.ac.id/eprint/46999/>
- Hermiana. 8 Desember 2024. Di Tengah Cuaca Ekstrem 2024, Produksi Padi Di Banyumas Mencapai 375.511 Ton. *Metro Jateng*. <https://metrojateng.com/2024/12/08/Di-Tengah-Cuaca-Ektrem-2024-Produksi-Padi-Di-Banyumas-Mencapai-375-511-Ton/>
- Hu, K., Zheng, X., Su, X., Wu, L., Liu, Y., & Deng, Z. 2025. Identification Of Rice Leaf Disease Based On Depmulti-Net. *Frontiers In Plant Science*, 16. <https://doi.org/10.3389/fpls.2025.1522487>
- Julianto, A., Sunyoto, A., & Wibowo, F. W. 2022. Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi. *TEKNIMEDIA: Teknologi Informasi Dan Multimedia*, 3(2), 98-105. <https://doi.org/10.46764/Teknimedia.V3i2.77>
- Khoiruddin, M., Junaidi, A., & Saputra, W. A. 2022. Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network. *Journal Of Dinda: Data Science*,

- Information Technology, And Data Analytics*, 2(1), 37-45.
<https://doi.org/10.20895/Dinda.V2i1.341>
- Mesran, Yahya, S. R., Nugroho, F., & Windarto, A. P. 2024. Investigating The Impact Of Relu And Sigmoid Activation Functions On Animal Classification Using CNN Models. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 8(1), 111-118.
<https://doi.org/10.29207/Resti.V8i1.5367>
- Norjamilah, N., Mariana, & Budi, I. S. 2021. Ketahanan Penyakit Bercak Coklat (Helminthosporium Sp.) Pada Padi Beras Merah, Padi Beras Hitam, Lokal Siam, Dan Unggul Ciherang. *Jurnal Proteksi Tanaman Tropika*, 4(3), 372-379.
<https://doi.org/10.20527/Jptt.V4i3.900>
- Pulungan, S. M., Febrianti, R., Lestari, T., Gurning, N., & Fitriana, N. 2023. Analisis Teknik Entity-Relationship Diagram Dalam Perancangan Database. *Jurnal Ekonomi Manajemen Dan Bisnis (JEMB)*, 1(2), 143-147.
<https://doi.org/10.47233/Jemb.V1i2.533>
- Rahman, M. M., Hosen, M. H., Chowdhury, R., Tasnia, N., Nawar, S., & Uddin, M. N. 2024. Automated Paddy Disease Detection: A Deep Learning Approach. *Proceedings Of The 3rd International Conference On Computing Advancements (ICCA 2024)*, 1026-1033. <https://doi.org/10.1145/3723178.3723314>
- Rustanto, D. W., Liantoni, F., & Prakisy, N. P. T. 2024. Identifikasi Penyakit Daun Pada Tanaman Padi Menggunakan Ekstraksi Fitur Gray Level Co-Occurrence Matrix (GLCM) Dan Metode K-Nearest Neighbour (KNN). *JUSTIN (Jurnal Sistem Dan Teknologi Informasi)*, 12(1), 100-106. <https://doi.org/10.26418/Justin.V12i1.69752>
- Soekarta, R., Nurdjan, N., & Syah, A. 2023. Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN). *INSECT (Informatics And Security): Jurnal Informatika Dan Keamanan*, 8(2), 143-151.
<https://doi.org/10.33506/Insect.V8i2.2356>
- Tan, M., & Le, Q. 2019. Efficientnet: Rethinking Model Scaling For Convolutional Neural Networks. *Proceedings Of The 36th International Conference On Machine Learning (ICML)*, PMLR 97, 6105-6114. <https://arxiv.org/abs/1905.11946>
- Wiggerthale, J., & Reich, C. 2024. Explainable Machine Learning In Critical Decision Systems: Ensuring Safe Application And Correctness. *AI*, 5(4), 2864-2896.
<https://doi.org/10.3390/Ai5040138>
- Yang, H. 2021. *Neural Network Tutorials - Herong's Tutorial Examples*.
<https://www.herongyang.com>
- Yuliany, S., Aradea, & Rachman, A. N. 2022. Implementasi Deep Learning Pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Buana Informatika*, 13(1), 54-65.
<https://doi.org/10.24002/Jbi.V13i1.5022>
- Zafar, A., Aamir, M., Mohd Naw, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A. K., & Almotairi, S. 2022. A Comparison Of Pooling Methods For Convolutional Neural Networks. *Applied Sciences*, 12(17), 8643. <https://doi.org/10.3390/App12178643>