

Model Convolutional Neural Network berbasis Data Lapangan untuk Deteksi Penyakit Daun Padi

Adi Suryadi^{1,*}, Suhirman²

¹ Program studi informatika, Universitas Teknologi Yogyakarta, Indonesia

² Program Studi Teknologi Informasi, Universitas Teknologi Yogyakarta, Indonesia

* Correspondence: adisuryadi807370@gmail.com

Copyright: © 2025 by the authors

Received: 13 Oktober 2025 | Revised: 1 November 2025 | Accepted: 6 Desember 2025 | Published: 12 Desember 2025

Abstrak

Deteksi dini penyakit daun padi merupakan komponen penting dalam menjaga produktivitas pertanian, terutama karena padi merupakan komoditas utama di Indonesia. Namun, penelitian mengenai *Convolutional Neural Network* (CNN) masih menggunakan dataset laboratorium yang homogen, sehingga kurang optimal ketika diterapkan pada kondisi lapangan yang bervariasi. Penelitian ini bertujuan mengembangkan sistem berbasis CNN untuk klasifikasi penyakit daun padi menggunakan citra lapangan. Jenis penelitian ini adalah pengembangan dengan menggunakan model waterfall. Tahapan ini terdiri dari analisis kebutuhan dengan pra-pemrosesan berupa *resizing* dan augmentasi, perancangan, serta implementasi dalam aplikasi web. Pengujian menggunakan black box untuk melihat fungsional dari sistem tersebut. Hasil temuan kami berupa sistem mampu melakukan klasifikasi penyakit daun dengan baik berdasarkan data lapangan tersebut, dan berfungsi dengan baik. Hasil pelatihan menunjukkan akurasi 94,64%, *precision* 0,93, *recall* 0,90, dan *F1-score* 0,91, dengan performa terbaik pada kelas *blast* dan *blight*. Kesalahan klasifikasi terutama terjadi pada kelas tungro karena kemiripan visual dengan *blast* pada fase awal infeksi. Sistem yang dibangun mampu melakukan diagnosis otomatis melalui unggahan citra dan menunjukkan stabilitas pembelajaran berdasarkan kurva akurasi dan *loss*. Penelitian ini berkontribusi dengan menyediakan sistem deteksi penyakit daun padi *end-to-end* berbasis data lapangan yang akurat, adaptif, dan siap digunakan untuk mendukung pemantauan kesehatan tanaman secara langsung di lingkungan pertanian.

Kata kunci: *augmentasi data; convolutional neural network; deep learning; deteksi penyakit padi; pengolahan citra digital*

Abstract

*Early detection of rice leaf diseases is an important component in maintaining agricultural productivity, especially since rice is a major commodity in Indonesia. However, research on Convolutional Neural Networks (CNN) still uses homogeneous laboratory datasets, which are less than optimal when applied to varying field conditions. This study aims to develop a CNN-based system for classifying rice leaf diseases using field images. This type of research is development using a waterfall model. These stages consist of needs analysis with pre-processing in the form of resizing and augmentation, design, and implementation in a web application. Testing was conducted using a black box to examine the functionality of the system. Our findings show that the system is capable of classifying leaf diseases well based on the field data and functions properly. The training results show an accuracy of 94.64%, precision of 0.93, recall of 0.90, and F1-score of 0.91, with the best performance in the *blast* and *blight* classes. Classification errors mainly occurred in the tungro class due to its visual similarity to *blast* in the early stages of infection. The developed system is capable of performing automatic diagnosis through image uploads and demonstrates learning stability based on the accuracy and loss curves. This research contributes by providing an end-to-end rice leaf disease detection system based on accurate, adaptive, and ready-to-use field data to support direct plant health monitoring in agricultural environments.*



Keywords: convolutional neural network; data augmentation; deep learning; digital image processing; rice disease detection

PENDAHULUAN

Padi memiliki peran yang sangat penting sebagai komoditas utama di Indonesia, sebagaimana beras merupakan makanan pokok utama bagi masyarakat Indonesia (Widyanto & Subanu, 2023). Seperti halnya di kabupaten subang yang memiliki area pesawahan 84.570 Hektar dengan menyumbang produksi padi terbesar ketiga di jawa barat (Adi et al., 2024). Namun, dalam proses menanam tanaman padi terdapat tantangan serius, salah satunya serangan penyakit daun yang terbukti dapat menurunkan pertumbuhan dan produksi tanaman padi secara signifikan (Marwan et al., 2023). Hal tersebut menciptakan kebutuhan teknologi yang serba otomatis dan efisien seperti CNN yang mampu mempercepat proses identifikasi penyakit padi serta mengurangi waktu yang diperlukan (Santosa et al., 2023). Oleh karena itu deteksi penyakit sangat penting untuk menjaga Kesehatan pada tanaman padi (Saleh et al., 2025).

Pemanfaatan pengolahan citra menjadi semakin penting dalam proses identifikasi penyakit daun tanaman padi. Pengolahsan citra merupakan proses manipulasi dan pemprosesan gambar dengan bantuan komputer untuk meningkatkan kualitas visual dari citra tersebut (Amalia & Dewi, 2024). Citra tersusun dari Kumpulan piksel atau titik-titik berwarna yang Bersama-sama membentuk suatu gambar (Hidayat, 2025). Teknik pengolahan citra menggunakan CNN. CNN merupakan metode *Deep Learning* yang dapat dilatih pada kumpulan data gambar berukuran besar untuk melakukan pengenalan serta pendekripsi objek didalam citra (Permadi & Gumiang, 2024; Triginandri & Subhiyakto, 2024). *Deep learning*, khususnya arsitektur CNN, mampu secara otomatis mempelajari dan mengekstraksi fitur penting dari citra digital sehingga sangat efektif digunakan dalam proses klasifikasi visual (Nurohman et al., 2024). Arsitektur CNN tersusun atas lapisan *konvolusi*, *aktivasi*, dan *pooling* yang bekerja berurutan untuk mengenali pola tepi, tekstur, dan bentuk, sementara fungsi *aktivasi* seperti *ReLU* memberikan *non-linearitas* agar jaringan dapat mempelajari fitur kompleks (Sufiya et al., 2025). Kombinasi lapisan tersebut memungkinkan CNN membedakan objek dengan karakteristik visual yang mirip tanpa rekayasa fitur manual, sebagaimana dijelaskan oleh (Putri & Rakasiwi, 2025).

Metode pembelajaran mesin tradisional seperti *Support Vector Machine* (SVM), *k-Nearest Neighbor* (k-NN), atau *Multilayer Perceptron* (MLP) umumnya memerlukan rekayasa fitur secara manual. Berbeda dengan CNN yang mampu mengekstraksi fitur penting langsung dari citra secara otomatis, sehingga proses analisis menjadi lebih efisien dan representasi visual yang dihasilkan cenderung lebih kuat. Metode konvensional umumnya mengharuskan proses ekstraksi fitur secara terpisah, seperti menggunakan GLCM, LBP, atau SIFT sebelum tahap klasifikasi, sehingga rentan terhadap kehilangan informasi penting. Sebaiknya teknologi pengolahan citra menggunakan teknologi yang lebih modern seperti CNN yang telah terbukti mampu mengidentifikasi pola visual yang kompleks (Prastita et al., 2025).

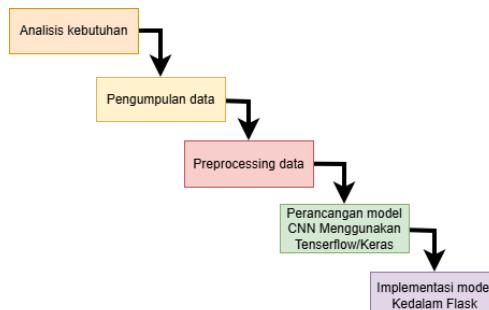
Keunggulan ini menjadikan CNN sangat relevan dalam citra pertanian, terutama dalam mendekripsi penyakit tanaman berbasis visual. Dalam bidang pertanian, CNN berhasil digunakan untuk mendekripsi penyakit daun padi menggunakan model *fusi* CNN dan *transformer* dengan akurasi 98,20% (Chakrabarty et al., 2024). mengklasifikasikan sembilan penyakit daun padi dengan model *ensemble* (DEX) yang mencapai akurasi 98% (Ahad et al., 2023), mendekripsi penyakit daun kentang menggunakan arsitektur ResNet50 (Chowdhury & Das, 2025), mendekripsi penyakit daun kentang (di antara delapan jenis tanaman lainnya) dengan akurasi hingga 100% menggunakan *Custom CNN* (Rahman et al., 2025)., Serta metode *Convolutional Neural Network* pada Sistem klasifikasi penyakit tanaman apel berdasarkan citra daun dengan akurasi 99,01% (Pamungkas & Suhendar, 2024),

Penelitian sebelumnya membuktikan bahwa CNN mampu melakukan klasifikasi terhadap beragam kondisi daun tanaman padi dengan Tingkat akurasi yang tinggi. Penelitian (Padhi et al., 2025) yang membahas diagnosis penyakit daun padi menggunakan model hibrida CNN-SVM memiliki akurasi 99,43%. Meski demikian, masih terdapat keterbatasan terkait variasi dataset dan kondisi pengujian yang dapat berdampak pada hasil klasifikasi (Mas'ud & Zeniarja, 2024). Penelitian ini memanfaatkan dataset lapangan dengan variasi jenis penyakit yang berbeda untuk meningkatkan kualitas sistem klasifikasi penyakit daun padi.

Penelitian ini bertujuan mengembangkan sistem deteksi penyakit daun padi berbasis CNN yang mampu melakukan klasifikasi secara cepat dan akurat melalui input citra daun. Fokus penelitian tidak hanya pada pembangunan model, tetapi juga pada pengembangan sistem yang dapat digunakan langsung oleh petani untuk mendukung proses diagnosis di lapangan. Sistem yang dirancang mampu memproses citra dengan variasi kondisi nyata, seperti perbedaan pencahayaan, sudut pengambilan gambar, dan tingkat keparahan penyakit. Hasil penelitian menunjukkan bahwa sistem mampu memberikan prediksi dengan akurasi tinggi dan bekerja secara konsisten pada data lapangan, sehingga memberikan kontribusi nyata dalam bentuk *Prototipe* aplikasi yang dapat mempercepat proses identifikasi penyakit serta membantu mengurangi risiko kerusakan tanaman padi.

METODE

Penelitian ini merupakan penelitian pengembangan sistem yang membangun model klasifikasi penyakit daun padi menggunakan CNN. Proses pengembangan meliputi analisis kebutuhan, pengumpulan dataset, pra-pemrosesan data citra, perancangan dan pelatihan model CNN menggunakan *TensorFlow*, serta implementasi model ke dalam sebuah aplikasi web menggunakan *framework flask*, disertai dengan proses pengujian sistem seperti ditunjukkan pada gambar 1.



Gambar 1. Alur proses penelitian

Analisis kebutuhan dilakukan dengan menetapkan tiga jenis penyakit daun padi yang menjadi fokus klasifikasi (*blast*, *blight*, dan *tungro*), menentukan kebutuhan jumlah data, serta merumuskan spesifikasi sistem berbasis CNN yang akan dikembangkan. Pengumpulan data dilakukan pada 9–22 Maret 2025 di area persawahan Kabupaten Subang dan menghasilkan 235 citra *bright*, 330 citra *blast*, dan 330 citra *tungro*. Dataset kemudian diproses melalui tahapan preprocessing, yaitu pembagian data menjadi 80% data latih dan 20% data uji sehingga setiap kelas memiliki 188–264 citra latih dan 47–66 citra uji pada tabel 1, penyesuaian ukuran citra menjadi 224×224 piksel, serta penerapan *augmentasi* berupa rotasi 20°, pergeseran horizontal/vertikal 0,2, dan horizontal flip. Seluruh langkah ini dilakukan untuk memastikan variasi data yang memadai dan mengurangi potensi overfitting selama pelatihan model CNN.

Tabel 1. Data citra daun padi

No	Kelas	Blight	Blast	Tungro
1	Total data	235	330	330
2	Data latih	188	264	264
3	Data uji	47	66	66
4	Data Gambar			

Setelah tahap *preprocessing* selesai, penelitian dilanjutkan ke perancangan model CNN menggunakan *TensorFlow/Keras*. Arsitektur jaringan terdiri dari tiga blok *convolutional* dengan 32, 64, dan 128 filter berukuran 3×3 yang menggunakan *aktivasi ReLU*, serta *MaxPooling2D* 2×2 pada setiap blok. Hasil ekstraksi fitur kemudian diratakan menggunakan *Flatten* dan diteruskan ke *Dense* 128 unit dengan *aktivasi ReLU* serta *Dropout* 0,5 untuk mencegah *overfitting*. Lapisan keluaran menggunakan *Dense* 3 unit beraktivasi *Softmax* untuk mengklasifikasikan tiga jenis penyakit (*blast*, *bright*, *tungro*). Model dilatih selama 20 *epoch* menggunakan *optimizer Adam*, *learning rate* 0,001, dan *loss categorical crossentropy* dengan *batch size* 32. Setelah model selesai dilatih, sistem diimplementasikan ke dalam aplikasi web berbasis *Flask* yang memungkinkan pengguna mengunggah citra daun padi dan memperoleh hasil prediksi secara otomatis. Selanjutnya pada persamaan 1 digunakan untuk mengukur kinerja sistem pada tahap pengujian, yaitu dengan menghitung sejauh mana prediksi yang dihasilkan model sesuai dengan label sebenarnya pada seluruh data uji.

Setelah model mencapai performa optimal, langkah selanjutnya adalah implementasi ke dalam aplikasi web yang dirancang untuk menyediakan layanan klasifikasi penyakit daun padi secara *real-time* melalui unggahan citra. Pengujian sistem dilakukan menggunakan metode *black box* untuk memverifikasi bahwa seluruh fungsi utama, termasuk unggah citra dan klasifikasi penyakit, berjalan sesuai spesifikasi. Pendekatan ini memastikan bahwa sistem tidak hanya menghasilkan model *deep learning* berperforma tinggi, tetapi juga mampu beroperasi secara efektif dalam skenario penggunaan nyata di lapangan.

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

Keterangan

- TP (*True Positive*) = Jumlah data positif yang diprediksi oleh model
- TN (*True Negative*) = Jumlah data negatif yang diprediksi benar oleh model.
- FP (*False Positive*) = Jumlah data negatif yang salah diprediksi positif oleh model.
- FN (*False Negative*) = Jumlah data positif yang salah diprediksi negatif oleh model.

HASIL DAN PEMBAHASAN

Hasil

Hasil analisis pelatihan menunjukkan bahwa model mampu mempelajari pola visual penyakit daun padi secara efektif. Proses pengembangan dimulai dari penentuan parameter pelatihan, seperti jumlah *epoch*, ukuran *batch*, *learning rate*, serta jumlah kelas, yang berfungsi sebagai konfigurasi dasar dalam mengoptimalkan proses pembelajaran pada data yang telah dibagi menjadi data latih dan validasi. Setelah konfigurasi ditetapkan, model CNN dilatih menggunakan dataset yang telah melalui proses pra-pemrosesan dan *augmentasi*.

```

Epoch 20/20
13/13 10s 792ms/step - accuracy: 0.9464 -
loss: 0.1747 - val_accuracy: 0.9400 - val_loss: 0.1247

```

Gambar 2 Hasil training

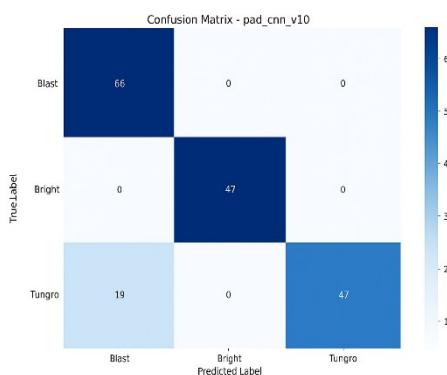
Hasil proses pelatihan model yang ditunjukkan pada gambar 2 memperlihatkan perkembangan akurasi dan *loss* selama proses pembelajaran. Selama pelatihan, dengan nilai akurasi dan *loss* dianalisis pada setiap *epoch* untuk menilai stabilitas proses pembelajaran. Pada *epoch* ke-20, model mencapai *training accuracy* sebesar 94,64% dan *validation accuracy* sebesar 94%, dengan *training loss* sebesar 0,1747 dan *validation loss* sebesar 0,1247. Keselarasan penurunan *loss* antara data latih dan validasi mengindikasikan bahwa model mengalami *konvergensi* yang stabil tanpa gejala *overfitting* yang berarti, sehingga dapat disimpulkan bahwa model mampu mempelajari karakteristik visual daun padi dengan optimal.

Evaluasi performa model berdasarkan metrik per kelas yang disajikan pada tabel 2 memberikan gambaran lebih rinci mengenai kemampuan klasifikasi pada setiap kategori penyakit. Kelas *blast* menunjukkan akurasi tertinggi sebesar 97,90%, diikuti *bright* sebesar 96,42%, sedangkan *tungro* memperoleh akurasi lebih rendah yaitu 89,60%. Nilai *precision* masing-masing kelas adalah 0,97 untuk *blast*, 0,96 untuk *bright*, dan 0,87 untuk *tungro*. Nilai *recall* mencapai 1,00 pada kelas *blast* dan *bright*, sementara kelas *tungro* hanya mencapai 0,71. Adapun *F1-score* masing-masing kelas tercatat sebesar 0,98; 0,98; dan 0,78. Secara keseluruhan, nilai rata-rata *precision* 0,93, *recall* 0,90, dan *F1-score* 0,91 menunjukkan bahwa model memiliki performa klasifikasi yang baik pada tiga kelas penyakit daun padi.

Namun, performa pada kelas *tungro* sedikit lebih rendah dengan *F1-score* 0,78 karena 19 data citra *tungro* diklasifikasikan sebagai *blast*. Hal ini disebabkan oleh kemiripan visual gejala awal antara kedua penyakit, di mana pola bercak coklat dan perubahan warna daun memiliki karakteristik yang tumpang tindih pada beberapa sampel. Kondisi ini mengindikasikan bahwa model masih memerlukan penambahan variasi citra *tungro*, khususnya pada tahap gejala awal, agar kemampuan diskriminatifnya dapat meningkat.

Tabel 2. Akurasi setiap kelas

Kelas Penyakit	Precision	Recall	F1-score	Akurasi perkelas
<i>Blast</i>	0,97	1,00	0,98	97,90%
<i>Bright</i>	0,96	1,00	0,98	96,42%
<i>Tungro</i>	0,87	0,71	0,78	89,60%
Rata-Rata (macro)	0,93	0,90	0,91	94,64%



Gambar 3. Confusion matrix

Berdasarkan *confusion matrix* yang terdapat pada gambar 3, yangmana terdapat beberapa kasus kesalahan klasifikasi pada kelas *Tungro* yang tertukar dengan *blast*. Hal ini menunjukkan bahwa model mengalami kesulitan dalam membedakan pola visual pada kedua kelas tersebut,

kemungkinan disebabkan oleh kemiripan tekstur atau warna daun pada kondisi tertentu maupun variasi citra *tungro* yang lebih besar.



Gambar 4. Grafik *training* dan *validation accuracy*

Pada gambar 4 menunjukkan grafik *training validation accuracy* yang menggambarkan perkembangan akurasi model selama proses pelatihan. Grafik tersebut menunjukkan peningkatan akurasi yang konsisten pada kedua jalur (*training* dan *validation*), dengan perbedaan yang relatif kecil hingga mencapai akurasi sebesar 94,64% untuk data pelatihan dan 94% untuk data validasi pada *epoch* ke-20. Pola ini mengindikasikan bahwa model belajar secara progresif dan stabil, tanpa adanya lonjakan atau penurunan tajam yang biasanya menandakan ketidakstabilan proses pelatihan.

Sementara itu, pada gambar 5 ditampilkan grafik *training validation loss* yang menunjukkan pola penurunan *loss* yang selaras antara data pelatihan dan data validasi. Hingga *epoch* ke-20, nilai *training loss* berada pada 0,1747, sedangkan *validation loss* berada pada 0,1247. Perbedaan yang tidak terlalu besar antara kedua kurva mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan. Dengan demikian, model tidak hanya mempelajari data pelatihan, tetapi juga mampu melakukan generalisasi dengan baik terhadap data baru yang belum pernah ditemui sebelumnya. Konsistensi pola penurunan *loss* ini turut memperkuat bahwa konfigurasi parameter pelatihan meliputi jumlah *epoch*, ukuran *batch*, jumlah kelas, dan *learning rate* telah memberikan kinerja pelatihan yang optimal.



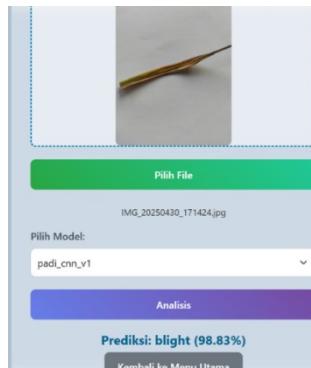
Gambar 5. Grafik *training* dan *validation loss*



Gambar 6. Tampilan halaman *upload*

Pada gambar 6 menunjukkan halaman upload pada Pada aplikasi web Klasifikasi jenis penyakit berbasis CNN dengan fitur upload gambar dengan menekan “pilih file” yang mana

pengguna dapat memilih file yang ingin di upload. Setelah gambar di upload kemudian pilih model CNN yang ingin digunakan. Untuk memulai proses analisis, user harus memilih tombol analisis yang mana hasilnya akan ditampilkan di bagian bawah tombol analisis Seperti pada gambar 7.



Gambar 7. Tampilan hasil klasifikasi

Pengujian sistem dilakukan menggunakan metode *black-box* untuk memastikan fungsi aplikasi berjalan sesuai kebutuhan. Berdasarkan hasil pada Tabel 3, seluruh skenario uji mulai dari proses unggah citra, hingga klasifikasi penyakit berjalan dengan baik dan menghasilkan keluaran yang sesuai. Setiap fitur dapat beroperasi tanpa kendala, sehingga sistem dinyatakan layak digunakan untuk proses deteksi penyakit daun padi.

Tabel 3. Hasil pengujian sistem

No	sekenario	Hasil yang dinginkan	Hasil Pengujian	Kesimpulan
1	Upload gambar	Gambar berhasil di upload untuk di proses	Sesuai yang diharapkan	Valid
2	Mengklasifikasi jenis penyakit	Menampilkan hasil klasifikasi dari gambar yang di upload sebelumnya	Sesuai yang diharapkan	Valid

Hasil pada tabel 3 menunjukkan terdapat dua skenario utama. pertama mengevaluasi kemampuan sistem dalam menyimpan gambar yang diunggah sebagai tahap awal analisis, dan hasilnya berjalan sesuai harapan. Skenario kedua menguji proses klasifikasi penyakit dari citra yang diunggah, di mana model CNN berhasil mengenali pola dan fitur daun tanaman padi dengan tingkat akurasi yang cukup baik. penelitian ini menunjukkan bahwa sistem mampu memproses gambar dengan baik serta memberikan informasi diagnose penyakit daun tanaman padi yang bermanfaat bagi para petani.

Pembahasan

Penelitian ini berhasil mengembangkan model CNN dengan akurasi sebesar 94,64%, yang menunjukkan potensi besar dalam mendeteksi penyakit daun padi serta membantu petani meminimalkan risiko penurunan hasil panen akibat serangan penyakit. Dataset citra yang digunakan dikumpulkan dari lahan pertanian di Kabupaten Subang, dengan fokus pada tiga jenis penyakit utama, yaitu *blast*, *blight*, dan *tungro*. Untuk meningkatkan keragaman data yang kemudian dilakukan proses *augmentasi* meliputi *rotation range*, *horizontal flip*, *width shift range*, dan *height shift range*.

Pemilihan CNN didasarkan pada kemampuannya dalam mengekstraksi fitur citra secara otomatis tanpa rekayasa fitur manual sebagaimana pada metode klasik seperti SVM, K-NN, atau ANN. Taye (2023) menjelaskan bahwa CNN membangun representasi fitur berjenjang

melalui proses konvolusi, sehingga mampu menangkap pola spasial penting seperti tepi, tekstur, dan bentuk yang bersifat translasi-invariant. Kemampuan hierarkis ini menjadikan CNN lebih unggul dalam menganalisis citra penyakit tanaman yang memiliki variasi visual kompleks.

Hasil analisis terhadap sistem menunjukkan bahwa seluruh komponen mulai dari *preprocessing*, pelatihan model, hingga proses inferensi dapat berjalan tanpa kendala signifikan. Pada tahap *preprocessing*, kualitas citra berhasil ditingkatkan melalui normalisasi dan *augmentasi*, sehingga data menjadi lebih representatif dan mengurangi risiko *overfitting*. Tahap pelatihan menunjukkan bahwa CNN mampu mempelajari pola penyakit secara konsisten, ditunjukkan oleh stabilitas kurva akurasi dan loss tanpa adanya divergensi antara data latih dan validasi. Pada tahap implementasi, *integrasi* model ke dalam aplikasi juga berjalan baik karena desain arsitektur sistem dibuat modular, sehingga proses pemanggilan model, pemrosesan citra, dan pengembalian hasil prediksi dapat dieksekusi secara efisien. Hasil ini mengindikasikan bahwa keberhasilan sistem bukan hanya berasal dari performa model CNN, tetapi juga dari kesesuaian *workflow* pengembangan, pengelolaan dataset yang baik, serta kelayakan arsitektur perangkat lunak yang diterapkan.

Namun demikian, masih ditemukan kesalahan klasifikasi pada kelas *tungro*, yang umumnya disebabkan oleh kemiripan visual dengan penyakit *blast* pada fase gejala awal. Ciri visual berupa bercak kecoklatan dan variasi pencahayaan di lapangan menyebabkan *feature map* CNN sulit membedakan keduanya. Kondisi ini sejalan dengan karakteristik CNN yang akurasinya dapat menurun apabila berhadapan dengan kelas yang memiliki kemiripan tekstur dan warna. Meski begitu, model tetap menunjukkan performa yang konsisten pada kelas lainnya yang memiliki pola visual lebih tegas sehingga secara keseluruhan masih dapat memberikan hasil klasifikasi yang dapat diandalkan.

Penelitian-penelitian sebelumnya menunjukkan bahwa performa model CNN sangat dipengaruhi oleh keragaman dataset serta kedalaman arsitektur yang digunakan. Sebagian studi masih memanfaatkan dataset yang bersifat homogen sehingga bergantung pada *augmentasi* intensif untuk menambah variasi data. Padhi et al. (2025) menyatakan bahwa *augmentasi* semacam ini justru dapat menghasilkan variasi yang tidak realistik dan menurunkan kemampuan generalisasi model pada kondisi lapangan. Di sisi lain, Christiawan et al. (2023) melaporkan akurasi lebih tinggi pada arsitektur InceptionV3 karena modelnya lebih dalam dan dilatih menggunakan data yang lebih stabil. Namun, mayoritas penelitian tersebut masih berfokus pada pengembangan model semata tanpa menyediakan sistem deteksi yang siap digunakan oleh pengguna di lingkungan pertanian yang sebenarnya.

Penelitian ini memberikan kontribusi yang berbeda melalui pembangunan sistem deteksi penyakit daun padi yang lengkap dan dapat dioperasikan, bukan sebatas pembuatan model CNN. Sistem yang dikembangkan mencakup proses pengelolaan dataset lapangan, *preprocessing* otomatis, pelatihan dan evaluasi model, serta integrasi ke dalam aplikasi web interaktif yang memungkinkan pengguna mengunggah citra daun dan menerima hasil diagnosis secara *real-time*. Pendekatan ini dirancang untuk menangani kondisi citra yang bervariasi di lingkungan pertanian nyata, seperti perubahan pencahayaan, sudut pemotretan, dan tingkat gejala yang tidak seragam. Dengan penggabungan komponen pemodelan dan aplikasi dalam satu *workflow* yang utuh, penelitian ini menghasilkan solusi deteksi penyakit daun padi yang tidak hanya akurat, tetapi juga praktis untuk mendukung aktivitas monitoring kesehatan tanaman di lapangan.

SIMPULAN

Hasil penelitian menunjukkan bahwa sistem deteksi penyakit daun padi berbasis CNN mampu mencapai akurasi 94,64% dengan performa klasifikasi yang konsisten pada data lapangan. Model yang dilatih menggunakan citra daun padi nyata ini mampu mengidentifikasi

tiga kategori penyakit secara akurat, sehingga membuktikan efektivitas pendekatan deep learning dalam diagnosis berbasis citra. Sistem yang dikembangkan juga berpotensi mendukung proses pengambilan keputusan di tingkat petani dengan memberikan hasil deteksi yang lebih cepat dan lebih tepat dibandingkan inspeksi manual. Meskipun demikian, tantangan masih ditemukan pada kelas penyakit dengan kemiripan visual tinggi, khususnya *tungro*, serta pada variasi pencahayaan di lingkungan lapangan. Optimalisasi lebih lanjut diperlukan untuk meningkatkan ketahanan model dan memperluas kompatibilitas sistem terhadap berbagai perangkat pencitraan.

REFERENSI

- Adi, R., Hasibuan, N. H., Sitohang, E. J., & Hayatuliman, M. (2024). Analisis kesesuaian lahan untuk tanaman padi sawah di kabupaten subang bagian tengah. *Agroista: Jurnal Agroteknologi*, 8(1), 20–28. <https://doi.org/10.55180/agi.v8i1.1200>
- Ahad, M. T., Li, Y., Song, B., & Bhuiyan, T. (2023). Comparison of CNN-based deep learning architectures for rice diseases classification. *Artificial Intelligence in Agriculture*, 9, 22–35. <https://doi.org/10.1016/j.aiia.2023.07.001>
- Amalia, V. F., & Dewi, R. R. (2024). Penilaian kesegaran ikan dengan metode K-nearest neighbor dan pengolahan citra digital. *Jurnal Mahasiswa Teknik Informatika*, 8(4), 7823–7829. <https://doi.org/10.36040/jati.v8i4.10441>
- Chakrabarty, A., Ahmed, S. T., Islam, M. F. U., Aziz, S. M., & Maidin, S. S. (2024). An interpretable fusion model integrating lightweight CNN and transformer architectures for rice leaf disease identification. *Ecological Informatics*, 82, 102718. <https://doi.org/10.1016/j.ecoinf.2024.102718>
- Chowdhury, S., & Das, D. K. (2025). Harnessing the potato leaf disease detection process through proposed Conv2D and resnet50 deep learning models. *Procedia Computer Science*, 252, 539–547. <https://doi.org/10.1016/j.procs.2025.01.013>
- Christiawan, G. Y., Putra, R. A., Sulaiman, A., Poerbaningtyas, E., & Putri Listio, S. W. (2023). Penerapan metode convolutional neural network (CNN) dalam mengklasifikasikan penyakit daun tanaman padi. *Journal of information and Technology*, 11(2), 294–306. <https://doi.org/10.32664/j-intech.v11i2.1006>
- Hidayat, T. (2025). Identifikasi morfologi citra daging menggunakan teknik pengolahan citra digital. *JATI (Jurnal Mahasiswa Teknologi Informatika)*, 9(1), 1580–1586. <https://doi.org/10.36040/jati.v9i1.12285>
- Marwan, H., Hayati, I., & Defitri, Y. (2023). Pengaruh aplikasi formula bakteri endofit terhadap perkembangan penyakit hawar daun bakteri, pertumbuhan, dan produksi tanaman padi. *Agrotekma: Jurnal Agroteknologi dan Ilmu Pertanian*, 8(1), 38–45. <https://doi.org/10.31289/agr.v8i1.10832>
- Mas'ud, R. A., & Zeniarja, J. (2024). Optimasi convolutional neural networks untuk deteksi kanker payudara menggunakan arsitektur denseNet. *Edumatic: Jurnal Pendidikan Informatika*, 8(1), 310–318. <https://doi.org/10.29408/edumatic.v8i1.25883>
- Nurohman, Heriansyah, R., Verano, D. A., & Mair, Z. R. (2024). Deteksi penyakit diabetes retinopathy menggunakan citra digital dengan metode convolutional neural network (CNN). November, 311–320. <https://doi.org/10.34151/prosidingsnast.v1i1.5120>
- Padhi, J., Mishra, K., Ratha, A. K., Behera, S. K., Sethy, P. K., & Nanthaamornphong, A. (2025). Enhancing paddy leaf disease diagnosis-a hybrid CNN model using simulated thermal imaging. *Smart Agricultural Technology*, 10, 100814. <https://doi.org/10.1016/j.atech.2025.100814>
- Pamungkas, N. B., & Suhendar, A. (2024). Penerapan metode convolutional neural network pada sistem klasifikasi penyakit tanaman apel berdasarkan citra daun. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 675–684. <https://doi.org/10.29408/edumatic.v8i2.27958>

- Permadi, M. L. B., & Gumilang, R. (2024). Penerapan Algoritma cnn (convolutional neural network) untuk deteksi dan klasifikasi target militer berdasarkan citra satelit. *Jurnal Sosial dan Teknologi (SOSTECH)*, 4(2), 134–143. <https://doi.org/10.59188/jurnalsostech.v4i2.1138>
- Prastita, D. A., Setiawan, A., & Ashari, I. F. (2025). Analisis perbandingan metode convolutional neural network (cnn) untuk deteksi warna pada objek. *Bulletin Of Computer Scince Research*, 5(4), 821–830. <https://doi.org/10.47065/bulletincsr.v5i4.617>
- Putri, C. A., & Rakasiwi, S. (2025). Diagnosis dini penyakit mata: klasifikasi citra fundus retina dengan convolutional neural network VGG-16. *Edumatic: Jurnal Pendidikan Informatika*, 9(1), 208–216. <https://doi.org/10.29408/edumatic.v9i1.29571>
- Rahman, K. N., Banik, S. C., Islam, R., & Fahim, A. Al. (2025). A real time monitoring system for accurate plant leaves disease detection using deep learning. *Crop Design*, 4(1), 100092. <https://doi.org/10.1016/j.cropd.2024.100092>
- Saleh, S. S., Koniyo, M. H., & Polin, M. (2025). Deteksi dini hama dan penyakit tanaman padi dengan metode yolo. *DIFFUSION journal Of Sysem and Information Technology*, 5(2), 173–182. <https://doi.org/10.61132/uranus.v2i3.259>
- Santosa, A. A., Fu’adah, R. Y. N., & Rizal, A. (2023). Deteksi penyakit pada yanaman padi menggunakan pengolahan citra digital dengan metode convolutional neural network. *JESCE (Journal of Electrical and System Control Engineering)*, 6(2), 98–108. <https://doi.org/10.31289/jesce.v6i2.7930>
- Sufiya, I., Umam, K., & Handayani, M. R. (2025). IKN Public Opinion on TikTok Before and After Efficiency Policy: CNN-LSTM on Imbalanced Data. *Edumatic: Jurnal Pendidikan Informatika*, 9(2), 402–411. <https://doi.org/10.29408/edumatic.v9i2.30123>
- Taye, M. M. (2023). Theoretical understanding of convolutional neural network: Concepts, architectures, applications, future directions. *Computation*, 11(3), 52. <https://doi.org/10.3390/computation11030052>
- Triginandri, R., & Subhiyakto, E. R. (2024). Deteksi Dini Cacar Monyet menggunakan Convolutional Neural Network (CNN) dalam Aplikasi Mobile. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 516–525. <https://doi.org/10.29408/edumatic.v8i2.27625>
- Widyanto, S., & Subanu, L. P. (2023). The factors of rice farmers' poverty in indonesia: the perspective of land conversion, land ownership area, and agriculture technologi. *Jurnal Kawisastra: The journal of social sciences and humanities*, 13(1), 121–134. <https://doi.org/10.22146/kawistara.78972>