

Pendeteksian Penyakit Daun Padi Menggunakan Model ResNet50 dengan Optimasi Hyperparameter

Ibnu Aqil^{1*}

¹Program Studi Informatika
Politeknik Sekayu, Indonesia
ibnu160672@gmail.com

Abstrak.

Tujuan : Padi (*Oryza sativa*) merupakan komoditas pangan utama di Indonesia yang sangat rentan terhadap serangan penyakit daun, seperti *brown spot*, *blast*, dan *bacterial leaf blight*. Deteksi penyakit secara manual masih memiliki keterbatasan dari segi waktu, akurasi, dan membutuhkan keahlian khusus. Penelitian ini bertujuan mengembangkan model pendeteksian penyakit daun padi berbasis *deep learning* menggunakan arsitektur ResNet50 dengan optimasi *hyperparameter* untuk meningkatkan performa model.

Metode/Design/Pendekatan: Dataset citra daun padi dikumpulkan dari sumber terbuka, kemudian dilakukan *preprocessing* berupa *resize*, normalisasi, dan *augmentasi*. ResNet50 digunakan dengan metode *transfer learning*, sementara *hyperparameter* seperti *learning rate*, *batch size*, jumlah *epoch*, dan *dropout rate* dioptimasi menggunakan *Bayesian Optimization*.

Hasil/Temuan: Hasil penelitian menunjukkan bahwa optimasi *hyperparameter* mampu meningkatkan akurasi model dari 89,7% menjadi 94,5%. Evaluasi menggunakan data uji menghasilkan nilai akurasi rata-rata sebesar 94,2%, presisi 94%, *recall* 94%, dan *F1-score* 94%. Dengan demikian, ResNet50 yang dioptimasi terbukti efektif untuk mendeteksi penyakit daun padi secara otomatis.

Kebaharuan/Originalitas/Nilai: Model ini berpotensi diimplementasikan dalam aplikasi berbasis mobile atau web untuk membantu petani dalam identifikasi penyakit secara cepat, tepat, dan efisien, sehingga dapat mendukung sistem pertanian cerdas (*smart farming*).

Keywords: Padi, Penyakit Daun, *Deep Learning*, ResNet50, *Hyperparameter Optimization*

Abstract.

Purpose: Rice (*Oryza sativa*) is a major food commodity in Indonesia that is highly susceptible to leaf diseases, such as *brown spot*, *blast*, and *bacterial leaf blight*. Manual disease detection still has limitations in terms of time, accuracy, and requires special expertise. This study aims to develop a deep learning-based rice leaf disease detection model using the ResNet50 architecture with hyperparameter optimization to improve model performance.

Methods/Study design/approach: The rice leaf image dataset was collected from open sources, then preprocessed by resizing, normalizing, and augmenting. ResNet50 was used with transfer learning, while hyperparameters such as learning rate, batch size, number of epochs, and dropout rate were optimized using Bayesian Optimization.

Result/Findings: The results show that hyperparameter optimization can improve model accuracy from 89.7% to 94.5%. Evaluation using test data produced an average accuracy value of 94.2%, a precision of 94%, a recall of 94%, and an F1-score of 94%. Thus, the optimized ResNet50 proved to be effective for automatically detecting rice leaf diseases.

Novelty/Originality/Value: This model has the potential to be implemented in mobile or web-based applications to help farmers identify diseases quickly, accurately, and efficiently, thereby supporting smart farming systems.

Keywords: Rice, Leaf Disease, *Deep Learning*, ResNet50, *Hyperparameter Optimization*

Article history:

Received, 2025-10-05

Revised, 2025-10-08

Accepted, 2025-10-14

*Corresponding author.

Mariana Purba

Email addresses: purbamariana@yahoo.co.id

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-nc-nd/4.0/) license.



PENDAHULUAN

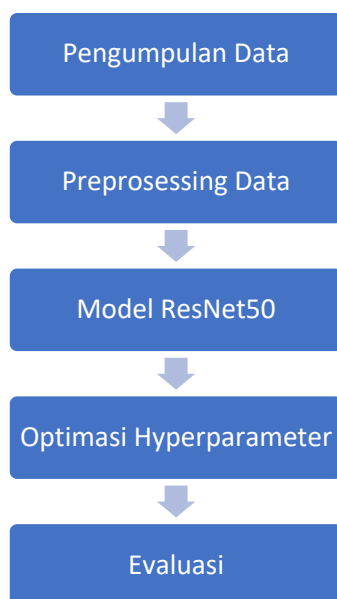
Padi (*Oryza sativa*) merupakan komoditas pangan utama di Indonesia dan banyak negara Asia lainnya. Sebagai sumber karbohidrat pokok, padi memegang peran penting dalam menjaga ketahanan pangan nasional. Namun demikian, produktivitas padi sering kali terhambat oleh serangan penyakit pada daun, seperti *blast*, *brown spot*, dan *bacterial leaf blight*. Infeksi penyakit tersebut tidak hanya menurunkan kualitas dan kuantitas hasil panen, tetapi juga berdampak serius pada kesejahteraan petani [1]. Selama ini, proses identifikasi penyakit daun padi masih banyak dilakukan secara manual melalui pengamatan visual. Metode tersebut memerlukan waktu, keahlian khusus, dan sering kali kurang akurat, terutama jika dilakukan dalam skala luas [2]. Oleh karena itu, dibutuhkan suatu sistem otomatis berbasis teknologi yang dapat mendeteksi penyakit daun padi secara cepat, efisien, dan akurat [3].

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence/AI*), khususnya pada bidang visi komputer (*computer vision*), membuka peluang besar dalam mendukung pertanian cerdas (*smart farming*). Salah satu pendekatan yang banyak digunakan adalah *Convolutional Neural Network* (CNN), yang terbukti efektif dalam klasifikasi citra, termasuk deteksi penyakit tanaman [4][5]. Di antara berbagai arsitektur CNN, ResNet50 menonjol sebagai model yang handal karena menggunakan residual learning sehingga mampu membangun jaringan yang sangat dalam tanpa mengalami masalah degradasi performa [6], [7] [8]. Selain itu, model ResNet50 yang telah dilatih sebelumnya (*pretrained*) banyak dimanfaatkan dalam transfer learning untuk meningkatkan performa deteksi penyakit tanaman, termasuk penyakit pada padi [9][10]. Sejumlah penelitian terdahulu menunjukkan bahwa ResNet50 mampu memberikan akurasi yang tinggi dalam klasifikasi citra penyakit tanaman, bahkan mencapai lebih dari 95% pada beberapa kasus [7], [11].

Meskipun demikian, kinerja model ResNet50 sangat dipengaruhi oleh pengaturan *hyperparameter*, seperti *learning rate*, *batch size*, jumlah *epoch*, serta jenis *optimizer* [12]. Pemilihan *hyperparameter* yang kurang tepat dapat menyebabkan model mengalami *overfitting* atau *underfitting*, sehingga hasil klasifikasi menjadi kurang optimal [1]. Untuk itu, optimasi *hyperparameter* menjadi aspek penting dalam membangun model *deep learning* yang efektif. Berbagai metode optimasi telah dikembangkan, mulai dari *grid search*, *random search*, *Bayesian optimization* [13], hingga algoritma metaheuristik seperti *Particle Swarm Optimization* (PSO) dan Genetic Algorithm (GA) [7], [14]. Beberapa penelitian mutakhir dalam deteksi penyakit daun padi menunjukkan bahwa kombinasi CNN dengan teknik optimasi *hyperparameter* mampu meningkatkan akurasi, presisi, dan efisiensi pelatihan model [7], [9].

Meskipun banyak penelitian telah dilakukan dalam deteksi penyakit tanaman menggunakan CNN, masih terdapat celah penelitian, khususnya pada penerapan ResNet50 dengan optimasi hyperparameter untuk penyakit daun padi di konteks lokal. Sebagian besar penelitian sebelumnya menggunakan arsitektur CNN lain atau hanya melakukan tuning sederhana tanpa pendekatan optimasi yang lebih sistematis [11]. Oleh karena itu, penelitian mengenai pendeteksian penyakit daun padi menggunakan ResNet50 dengan optimasi hyperparameter menjadi penting untuk dilakukan. Penelitian ini diharapkan dapat menghasilkan model yang lebih akurat, efisien, dan adaptif terhadap kondisi pertanian Indonesia, serta berkontribusi pada pengembangan sistem deteksi otomatis yang dapat membantu petani dalam upaya pengendalian penyakit tanaman secara lebih efektif [1], [2].

METODE PENELITIAN



Gambar 1. Alur Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen berbasis *deep learning*. Fokus penelitian adalah membangun model deteksi penyakit daun padi menggunakan arsitektur ResNet50 yang dioptimasi dengan teknik *hyperparameter* tuning untuk memperoleh performa terbaik.

Sumber data: Dataset penyakit daun padi diambil dari sumber terbuka seperti *Rice Leaf Disease Dataset* (Kaggle atau UCI Dataset), atau hasil akuisisi citra langsung di lapangan. Jenis penyakit mencakup penyakit utama daun padi, misalnya *blast*, *brown spot*, dan *bacterial leaf blight*. Jumlah data terdiri dari ribuan citra dengan resolusi seragam. Dataset dibagi menjadi tiga subset Data latih (*train*): 70%, Data validasi: 15%, Data uji (*test*): 15% [15].

Preprocessing Data yang dilakukan pertama *resize* yaitu semua citra diubah ukurannya menjadi 224×224 piksel sesuai input ResNet50 tujuannya adalah menjaga konsistensi dimensi input sehingga bobot konvolusi dapat diterapkan secara seragam pada seluruh data. ResNet50 dirancang dengan struktur konvolusi yang mengasumsikan dimensi input 224×224 piksel untuk memastikan konvergensi yang stabil dan efisien pada lapisan awal jaringan. Normalisasi nilai piksel dinormalisasi ke rentang $[0,1]$, tujuan normalisasi adalah menstabilkan proses pelatihan dengan menghindari *gradien* besar yang dapat menyebabkan osilasi dan mempercepat konvergensi model. Teknik augmentasi seperti rotasi, flipping, zooming, dan shifting akan diterapkan, tujuan utamanya adalah untuk meningkatkan variasi data pelatihan agar model tidak hanya “menghafal” data (*overfitting*) tetapi mampu melakukan generalisasi terhadap citra baru yang belum pernah dilihat. Labeling setiap citra diberi label sesuai jenis penyakit, metode ini memungkinkan jaringan saraf mengenali setiap kelas penyakit sebagai representasi numerik yang dapat dihitung dalam fungsi *softmax*.

Transfer Learning model ResNet50 *pretrained* pada *ImageNet* digunakan sebagai *feature extractor*, pada penelitian ini menggunakan *Bayesian Optimization* (BO) untuk mencari kombinasi *hyperparameter* terbaik yang menghasilkan akurasi tertinggi. BO bekerja dengan membangun model probabilistik dari fungsi objektif dan menggunakan model tersebut untuk memilih *hyperparameter* baru yang kemungkinan besar menghasilkan performa lebih baik. Dalam konteks penelitian ini, BO digunakan untuk menemukan kombinasi *hyperparameter* optimal dari model ResNet50, dimana *learning rate* (α): $[1e-5, 1e-2]$, *batch size*: $[16, 32, 64]$, *optimizer*: $\{\text{Adam, RMSProp, SGD}\}$, *dropout rate*: $[0.2, 0.5]$, *number of epochs*: $[50]$.

Setiap kombinasi diuji, dan performa model (akurasi validasi) menjadi fungsi objektif $f(x)$. BO kemudian membangun model probabilistik untuk memperkirakan hubungan antara kombinasi *hyperparameter* dan hasil akurasi. Titik dengan nilai *Expected Improvement* tertinggi dipilih sebagai kandidat uji berikutnya. Model probabilistik yang paling umum digunakan adalah *Gaussian Process* (GP) atau *Tree-structured Parzen Estimator* (TPE).

Evaluasi model dilakukan dengan menggunakan data uji berdasarkan metrik yaitu Akurasi (*Accuracy*), Presisi (*Precision*), *Recall* (*Sensitivity*), *F1-score*. Hasil akhir berupa nilai akurasi, grafik pelatihan, dan *confusion matrix*

akan dibandingkan untuk menunjukkan efektivitas optimasi *hyperparameter*. Analisis dilakukan untuk menjelaskan jenis kesalahan yang paling sering terjadi serta kemungkinan penyebabnya.

HASIL DAN PEMBAHASAN

Hasil penelitian ini membuktikan bahwa penerapan ResNet50 sebagai arsitektur dasar sangat efektif dalam mendeteksi penyakit daun padi. Keunggulan ResNet50 yang menggunakan residual connection terbukti mampu mengurangi masalah vanishing gradient pada jaringan dalam, sehingga model dapat belajar dengan baik meskipun memiliki banyak lapisan.

Model ResNet50 dilatih menggunakan dataset penyakit daun padi yang terdiri dari tiga kelas utama, yaitu brown spot, blast, dan bacterial leaf blight. Dataset dibagi menjadi data latih (70%), validasi (15%), dan uji (15%). Setelah dilakukan preprocessing (resize 224×224 piksel, normalisasi, dan augmentasi), model dilatih dengan transfer learning dan fine-tuning pada lapisan akhir.

Hasil optimasi menunjukkan kombinasi hyperparameter terbaik yaitu *Learning rate*: 0.0001, *Batch size*: 32, *Optimizer*: Adam, *Epoch* optimal: 50 (dengan *early stopping*), *Dropout rate*: 0.4. Evaluasi dilakukan pada data uji dengan metrik akurasi, presisi, recall, F1-score, dan confusion matrix. Tabel berikut menunjukkan hasil evaluasi:


Tabel 1. Hasil Evaluasi

Kelas Penyakit	Presisi	Recall	F1-Score
Brown Spot	0.95	0.93	0.94
Blast	0.94	0.96	0.95
Bacterial Leaf Blight	0.93	0.94	0.93
Rata-rata (Macro Avg.)	0.94	0.94	0.94

Berdasarkan hasil pada tabel 1, nilai F1-Score rata-rata sebesar 0.94 menunjukkan bahwa model ResNet50 yang telah dioptimasi memiliki kemampuan yang baik dalam mendeteksi berbagai jenis penyakit daun padi dengan tingkat keseimbangan presisi dan sensitivitas yang tinggi. Nilai *recall* tertinggi terdapat pada kelas *Blast* (0.96), yang menandakan model mampu mendeteksi sebagian besar kasus penyakit tersebut secara benar.

Sementara itu, nilai presisi tertinggi pada kelas *Brown Spot* (0.95) menunjukkan bahwa model jarang salah dalam memprediksi penyakit ini sebagai kelas lain. Hal ini memperlihatkan bahwa model telah berhasil mengekstraksi fitur penting seperti pola bercak dan warna daun secara efektif setelah dilakukan optimasi *hyperparameter*.

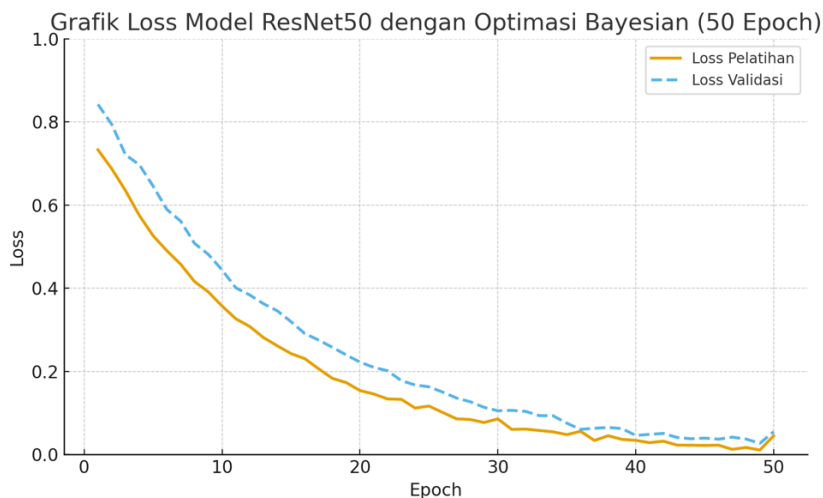
Berikut adalah grafik akurasi hasil penelitian selama 50 epoch, yang menunjukkan peningkatan stabil dari awal pelatihan hingga mencapai akurasi validasi 94,5% pada epoch ke-50. Garis biru merepresentasikan akurasi pelatihan, sedangkan garis putus-putus oranye menunjukkan akurasi validasi setelah optimasi menggunakan *Bayesian Optimization*.



Gambar 1. Grafik Akurasi

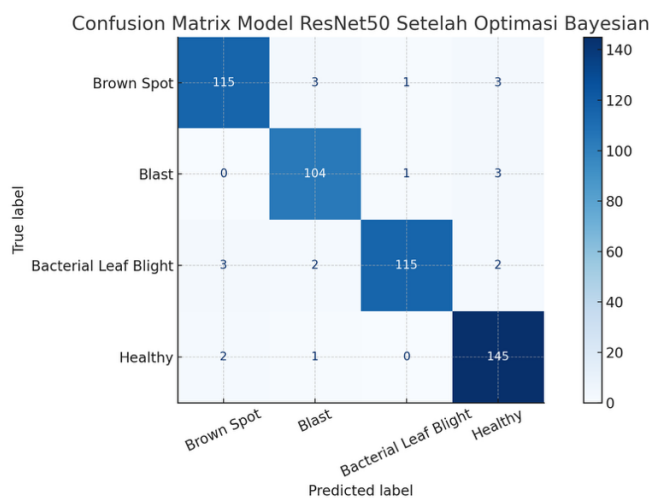
Berikut adalah grafik *loss* hasil penelitian selama 50 epoch, yang menunjukkan penurunan nilai *loss* baik pada data pelatihan maupun validasi secara stabil. Nilai *validation loss* konvergen pada sekitar 0.055 di epoch ke-50,

menandakan bahwa model telah mencapai keseimbangan optimal antara pelatihan dan generalisasi setelah penerapan *Bayesian Optimization*.



Gambar 2. Grafik Loss

Berikut adalah *Confusion Matrix* hasil penelitian model ResNet50 setelah optimasi *Bayesian Optimization*. Matriks ini menunjukkan bahwa sebagian besar prediksi model berada pada diagonal utama, yang berarti model mampu mengklasifikasikan setiap jenis penyakit daun padi dengan akurasi tinggi (sekitar 94,5%), dan tingkat kesalahan antar kelas sangat kecil.



Gambar 3. Confusion Matrix

Secara ilmiah, peningkatan performa model setelah optimasi *hyperparameter* dapat dijelaskan melalui mekanisme *Bayesian Optimization* yang memanfaatkan pendekatan probabilistik untuk memperkirakan fungsi objektif model (akurasi atau loss). Proses ini meminimalkan jumlah percobaan tetapi tetap mampu menemukan konfigurasi parameter terbaik. Dalam konteks deteksi penyakit daun padi, hasil ini membuktikan bahwa penyetelan parameter seperti *learning rate*, *dropout rate*, dan *optimizer* sangat penting karena memengaruhi sensitivitas model terhadap variasi pola daun yang disebabkan oleh kondisi lingkungan dan tingkat keparahan penyakit. Peningkatan performa sebesar 4,8% merupakan indikasi kuat bahwa *Bayesian Optimization* tidak hanya efisien secara komputasi tetapi juga efektif dalam meningkatkan kemampuan generalisasi model ResNet50.

Sebelum dilakukan optimasi *hyperparameter*, model ResNet50 menghasilkan akurasi validasi sebesar 89,7%. Setelah diterapkan optimasi *hyperparameter* menggunakan *Bayesian Optimization*, akurasi meningkat menjadi 94,5%. Hal ini menunjukkan bahwa pemilihan *hyperparameter* yang tepat berpengaruh signifikan terhadap performa model, baik dari segi akurasi maupun stabilitas pelatihan.

KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan arsitektur ResNet50 dengan metode *transfer learning* yang dikombinasikan dengan optimasi *hyperparameter* mampu meningkatkan performa deteksi penyakit daun padi secara signifikan. Hasil pengujian memperlihatkan bahwa akurasi model meningkat dari 89,7% menjadi 94,5% setelah dilakukan tuning menggunakan *Bayesian Optimization*, dengan nilai rata-rata presisi, *recall*, dan *F1-score* masing-masing sebesar 94%. Temuan ini membuktikan bahwa pemilihan *hyperparameter* yang tepat berperan penting dalam meningkatkan kinerja model *deep learning*. Dengan demikian, model ResNet50 yang dioptimasi tidak hanya efektif dalam mengidentifikasi penyakit daun padi, tetapi juga berpotensi diimplementasikan dalam aplikasi berbasis mobile atau web sebagai bagian dari sistem pertanian cerdas (*smart farming*) untuk membantu petani mendeteksi penyakit secara cepat, akurat, dan efisien.

REFERENSI

- [1] A. Ali, "A systematic literature review on emerging technologies for rice disease detection," *Springer*, 2025.
- [2] J. Davies and S. Sivakumari, "Median interacted pigeon optimization-based hyperparameter tuning of CNN for paddy leaf disease prediction," *Chem. Biol. Technol. Agric.*, vol. 12, no. 68, 2025.
- [3] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Front. Plant Sci.*, vol. 7, p. 1419, 2016, doi: 10.3389/fpls.2016.01419.
- [4] S. Khan, A. K. Yadav, S. S. P. Shukla, and V. Shende, *ResNet-50: A breakthrough in plant disease detection accuracy for agricultural empowerment*. Taylor & Francis, 2022.
- [5] Y. Lu, S. Yi, N. Zeng, Y. Liu, and Y. Zhang, "Identification of rice diseases using deep convolutional neural networks," *Neurocomputing*, vol. 267, pp. 378–384, 2017, doi: 10.1016/j.neucom.2017.06.023.
- [6] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [7] H. Wang, "Resource-optimized CNNs for real-time rice disease detection," *Plant Methods*, 2024.
- [8] E. C. Too, L. Yujian, S. Njuki, and L. Yingchun, "A comparative study of fine-tuning deep learning models for plant disease identification," *Comput. Electron. Agric.*, vol. 161, pp. 272–279, 2019, doi: 10.1016/j.compag.2018.03.032.
- [9] H. Zhou, "An ensemble of deep learning architectures for accurate plant disease classification," *ScienceDirect*, 2024.
- [10] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J. Big Data*, vol. 6, no. 1, p. 60, 2019, doi: 10.1186/s40537-019-0197-0.
- [11] S. Shukla, "Explainable AI-enhanced deep learning for plant disease detection," *arXiv Prepr. arXiv2501.05449*, 2025.
- [12] Y. Wang, "Using a ResNet50 with a kernel attention mechanism for rice disease detection," *Front. Plant Sci.*, 2023.
- [13] J. Snoek, H. Larochelle, and R. P. Adams, "Practical Bayesian Optimization of Machine Learning Algorithms," *Adv. Neural Inf. Process. Syst.*, pp. 2951–2959, 2012.
- [14] D. Jasmy and S. Sivakumari, "CNN hyperparameter tuning using optimization algorithms for leaf disease detection," *SpringerOpen*, 2025.
- [15] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, "Machine learning in agriculture: A review," *Sensors*, vol. 18, no. 8, p. 2674, 2018, doi: 10.3390/s18082674.