

Implementasi Metode CNN Menggunakan Arsitektur Resnet101 Pada Citra Penyakit Daun Padi

Shintyadhita Wirawan Putri, Volem Alvaro Azira, Talitha Aurora Nadenggan Siregar,
Rafani Bardatus Salsabilah, *Fetty Tri Anggraeny

Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur

Artikel Histori:

Disubmit: April 2025
Diterima: Mei 2025
Diterbitkan: Juni 2025

DOI

[10.33005/jifti.v7i1.157](https://doi.org/10.33005/jifti.v7i1.157)



ABSTRAK

Indonesia sebagai negara agraris memiliki peran penting dalam sektor pertanian terhadap perekonomian negara. Salah satu komoditas utama yang menjadi tulang punggung sektor ini adalah padi. Namun, produktivitas tanaman padi seringkali terganggu akibat penyakit seperti bacterial leaf blight, brown spot, dan leaf smut yang menyerang daun dari tanaman tersebut. Model yang dikembangkan, kemudian diuji menggunakan beberapa metrik seperti akurasi, precision, recall, dan f1-score yang berfungsi sebagai alat ukur performa model. Tujuan dari penelitian ini adalah pengembangan sistem klasifikasi penyakit daun padi menggunakan metode CNN dengan model ResNet101. Hasil penelitian menunjukkan bahwa model ResNet101 dapat mengenali penyakit pada daun padi dengan nilai akurasi sebesar 33% pada data validasi yang masih harus ditingkatkan kembali pada beberapa kelasnya. Harapan dari penelitian ini adalah dapat mendiagnosis penyakit tanaman padi secara otomatis, yang diharapkan dapat mempercepat deteksi dan penanggulangan penyakit pada tanaman padi. Pengembangan riset berikutnya dapat diarahkan pada optimalisasi keseimbangan data serta pemanfaatan teknik penanganan overfitting yang lebih variatif.

Kata Kunci: CNN, ResNet101, Penyakit Daun Padi, Klasifikasi, Deteksi Penyakit Tanaman.

How to Cite:

Putri, S. W., Azira, V. A., Siregar, T. A. N., Salsabilah, R. B., Anggraeny, F. T. (2025). Implementasi Metode CNN Menggunakan Arsitektur Resnet101 Pada Citra Penyakit Daun Padi. *Jurnal Ilmiah Teknologi Informasi dan Robotika*, 7(1), 51-60. <https://doi.org/10.33005/jifti.v7i1.157>.

***Corresponding Author:**

Email : fettyanggraeny.if@upnjatim.ac.id
Alamat : Jl. Raya Rungkut Madya, Gunung Anyar, Surabaya l.
Rungkut Madya No.1



This article is published under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).

PENDAHULUAN

Sebagai negara agraris, Indonesia memiliki sektor pertanian yang memberikan kontribusi signifikan terhadap perekonomian nasional. (Andikayani, 2023). Padi, sebagai komoditas pangan utama, merupakan tanaman krusial yang mendukung ketahanan pangan masyarakat. Namun, produktivitas tanaman padi kerap terganggu oleh sejumlah penyakit yang menyerang daun tanaman, seperti *bacterial leaf blight*, *brown spot*, dan *leaf smut* (Oktaviana, 2021).

Kemajuan kecerdasan buatan (AI) dan pengolahan citra, telah membuka peluang untuk mengembangkan sistem diagnosis penyakit tanaman yang lebih cepat, akurat, dan efisien. Pendekatan yang dapat diterapkan dalam penelitian ini adalah Convolutional Neural Network (CNN), yang merupakan algoritma Deep Learning hasil pengembangan dari konsep Multi Layer Perceptron (MLP). Algoritma ini menonjol dalam pengenalan citra karena mampu meniru cara kerja otak manusia dalam mengidentifikasi gambar. Dengan pendekatan ini, CNN memiliki kemampuan unggul dalam mengolah dan memahami informasi visual secara efisien (Putra et al., 2021). CNN telah terbukti unggul dalam menganalisis citra, termasuk klasifikasi penyakit tanaman, karena kemampuannya dalam mengekstraksi fitur visual yang kompleks (Khan et al., 2021). Dalam penelitian ini, diterapkan model ResNet101, yang dikenal memiliki keunggulan dalam menangani permasalahan degradation problem pada jaringan yang sangat dalam, sehingga mampu menghasilkan ekstraksi fitur yang lebih optimal dari citra daun padi yang terinfeksi.


Penelitian ini bertujuan menerapkan metode CNN berbasis model ResNet101 pada citra penyakit daun padi. Teknik augmentasi data digunakan untuk menangani ketidakseimbangan data, mencegah overfitting, serta meningkatkan kualitas dan kuantitas data latih, dengan menerapkan *rotation*, *zoom*, dan *flipping horizontal* (Shorten & Khoshgoftaar, 2019).

Penelitian sebelumnya menunjukkan bahwa CNN, khususnya ResNet101, memiliki performa yang unggul dalam klasifikasi citra, termasuk pengklasifikasian penyakit tanaman. Oktaviana et al. (2021) dengan menerapkan transfer learning berbasis ResNet101, penelitian ini berhasil mengklasifikasikan tiga jenis penyakit daun padi *Bacterial Leaf Blight*, *Brown Spot*, dan *Leaf Smut* serta memperoleh akurasi validasi sebesar 100% dan loss sebesar 5,61%. Teknik augmentasi data, meliputi *rotation*, *zoom*, dan *flipping horizontal*, digunakan dalam penelitian ini untuk menangani ketidakseimbangan dataset yang berdampak pada peningkatan kemampuan generalisasi model. Rahman et al. (2020) mengungkapkan keunggulan algoritma CNN dalam identifikasi penyakit dan hama padi melalui pendekatan deep learning, dengan akurasi 93,3% serta ukuran model yang 99% lebih sederhana dibandingkan model VGG. Selain itu, Islam et al. (2021) melaporkan bahwa CNN mampu melakukan klasifikasi penyakit daun padi dengan akurasi mencapai 92,68%. Selain itu, studi dalam bidang kesehatan juga menunjukkan efektivitas ResNet101 dalam pengklasifikasian citra medis, seperti analisis X-ray untuk deteksi infeksi COVID-19 (Nawaz et al., 2023).

Diharapkan pada penelitian ini dapat meningkatkan akurasi klasifikasi tiga jenis penyakit pada daun padi. Evaluasi performa model dilakukan melalui metrik akurasi, presisi, recall, dan F1-score untuk memastikan hasil yang optimal.

METODE PENELITIAN

Dalam melakukan penelitian ini, alur sistematis yang digunakan dengan mengikuti urutan pelaksanaan yang telah direncanakan berdasarkan jurnal literatur yang digunakan sebagai referensi.




Gambar 1. Alur Penelitian
Sumber: Data Diolah

Alur penelitian dari tahap awal hingga tahap akhir ditunjukkan pada Gambar 1. Proses pertama yang akan dilakukan adalah pengambilan dataset yang didapatkan dari gabungan beberapa dataset yang memiliki judul dataset Rice Leaf Diseases. Melalui dataset tersebut, selanjutnya akan dilakukan pre-processing data berupa pembagian data menjadi data train dan data validation, yang selanjutnya akan masuk ke proses augmentasi yang berfungsi untuk merepresentasikan (memperbanyak) data dari citra asli untuk mengatasi ketidakseimbangan kelas yang ada di dataset. Selanjutnya, proses pembuatan dan pelatihan model yang dilanjutkan dengan mengevaluasi model. Proses augmentasi data yang dilakukan menghasilkan data latih baru yang digunakan untuk memaksimalkan ekstraksi fitur dan kemampuan generalisasi model ditingkatkan agar mampu mengenali citra dengan variasi kondisi yang beragam.

Dataset

Penelitian ini menggunakan dataset gabungan dari beberapa sumber mencakup tiga kelas penyakit, yakni *Bacterial Leaf Blight*, *Brown Spot*, dan *Leaf Smut*. Dalam mengatasi ketidakseimbangan jumlah data antar kelas, dilakukan proses penyamarataan dataset pada masing-masing kelas penyakit. Jumlah akhir dataset yang digunakan adalah sebanyak 500 dataset per masing-masing penyakit.

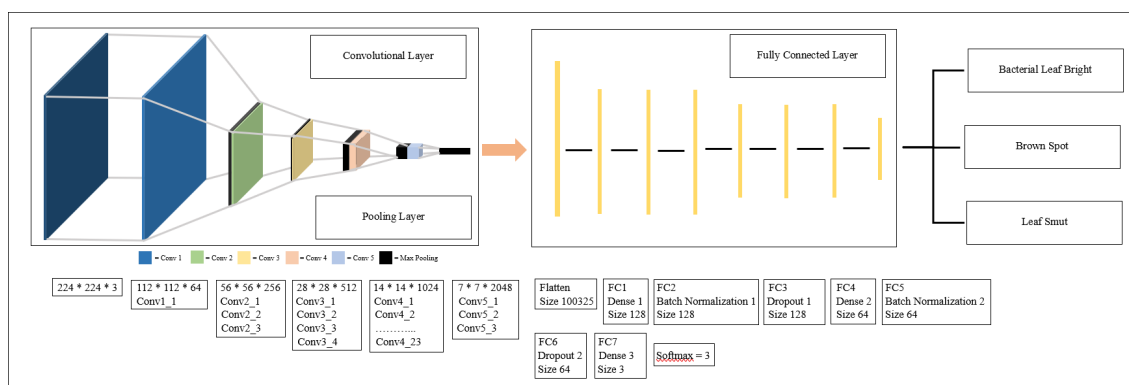


Gambar 2. Citra pada Penyakit Daun Padi
Sumber: Data Diolah

Gambar 2 menunjukkan data yang digunakan merupakan citra penyakit daun padi yang terdiri dari 3 kelas. Gambar (a) menunjukkan sample dari daun yang terjangkit penyakit bacterial leaf blight. Kemudian, gambar (b) menunjukkan sample dari daun yang terjangkit penyakit brown spot. Terakhir, gambar (c) menunjukkan sample dari daun yang terjangkit penyakit leaf smut. Dari data yang digunakan tersebut, dilakukan proses augmentasi untuk pemerataan data agar keseimbangan data jauh lebih optimal sehingga nantinya akan terhindar dari overfitting.

Perancangan Arsitektur Model

Model yang digunakan adalah CNN dengan arsitektur ResNet101, yang diadaptasi untuk klasifikasi gambar daun padi. Model ResNet101 memiliki struktur lapisan residual yang dirancang untuk mengatasi degradation problem atau penurunan akurasi yang sering terjadi pada jaringan yang sangat dalam. Penyesuaian dilakukan pada bagian Fully Connected Layer (FC Layer) dengan menambahkan lapisan-lapisan yang ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur Model yang Dirancang
Sumber: Data Diolah

1. Dense Layer: Menggunakan 128 neuron dengan fungsi aktivasi 'relu' untuk memperkuat fitur yang telah diekstrak.
2. BatchNormalization Layer: Digunakan setelah Dense Layer pertama untuk menjaga stabilitas distribusi data, mempercepat konvergensi, dan mengurangi risiko overfitting.
3. Dropout Layer: Menggunakan dropout rate 0,5 untuk meminimalkan *overfitting* dengan menonaktifkan *neuron* secara acak saat pelatihan.

4. Dense Layer: Menggunakan 64 neuron dengan fungsi aktivasi 'relu' untuk mengekstrak fitur yang lebih mendalam.
5. BatchNormalization Layer: Digunakan kembali untuk stabilisasi data dan memperbaiki generalisasi model.
6. Dropout Layer: Dropout Layer kedua diterapkan dengan dropout rate sebesar 0.4 untuk mempertahankan generalisasi dan mengurangi overfitting lebih lanjut.
7. Dense Layer Output: Sebagai lapisan output, Dense Layer ini memiliki 3 neuron, yang masing-masing mewakili kelas penyakit pada daun padi.

Augmentasi Data

Sebagai tahapan krusial, augmentasi data berperan dalam meningkatkan keragaman data pelatihan guna membantu model mengenali pola yang lebih kompleks serta menekan kemungkinan terjadinya overfitting. Pada penelitian ini, tiga teknik augmentasi diterapkan, yaitu rotasi, zoom, dan *flipping horizontal*.

1. Rotasi Gambar

Rotasi gambar dilakukan untuk mengatasi perbedaan orientasi pada citra daun padi. Dengan merotasi gambar sebesar 20 derajat, model dapat lebih adaptif terhadap berbagai posisi gambar yang mungkin ditemukan dalam data yang sebenarnya. Rotasi ini membantu model mengenali fitur dari daun yang mungkin tampak dari sudut berbeda.

2. Zoom Gambar

Zoom gambar diterapkan untuk mensimulasikan variasi ukuran objek dalam gambar. Pada proses ini, gambar diperbesar atau diperkecil hingga 40% dari ukuran aslinya. Teknik zoom memberikan variasi skala pada citra yang dilihat oleh model.

3. Flipping Horizontal

Teknik flipping horizontal (pembalikan horizontal) digunakan untuk menciptakan gambar yang merupakan cerminan dari gambar asli. Teknik ini menambah variasi pada data dengan mempertimbangkan pola yang sama dari sisi yang berlawanan, sehingga model dapat lebih mudah mengenali objek meskipun orientasinya berbeda.

Ketiga teknik augmentasi tersebut digabungkan dalam satu alur pemrosesan guna menjamin tersedianya data latih yang lebih bervariasi. Dengan pendekatan ini, model diharapkan dapat memahami pola secara lebih optimal serta menjaga kinerja yang baik ketika diterapkan pada data baru yang belum pernah digunakan dalam proses pelatihan.

Pelatihan Model

Jumlah dataset yang digunakan total 500 citra pada setiap kelas. Dataset selanjutnya dibagi menjadi 70% data pelatihan dan 30% data validasi untuk mendukung pelatihan serta evaluasi model dengan distribusi data yang seimbang.

Tabel 1
Tabel Pembagian Dataset

<i>Bagian</i>	<i>Jumlah Data</i>	<i>Bacterial leaf blight</i>	<i>Brown spot</i>	<i>Leaf smut</i>
Data Train	1.050	350	350	350
Data Validation	450	150	150	150

Dalam penelitian ini, diterapkan dua fungsi callback untuk memantau dan mengoptimalkan proses pelatihan model dengan tujuan meningkatkan efisiensi dan performa model. Fungsi callback digunakan untuk mengeksekusi tindakan tertentu selama proses pelatihan berdasarkan kriteria yang telah ditentukan, seperti menghentikan pelatihan saat terjadi overfitting atau menyimpan model terbaik secara otomatis. Berikut adalah penjelasan lebih rinci tentang dua fungsi callback yang digunakan:

1. *Callback EarlyStopping*

Guna mengoptimalkan proses pelatihan, mekanisme *EarlyStopping* diterapkan sebagai alat kendali otomatis berbasis nilai *validation loss*. Callback ini diprogram untuk memutus siklus iterasi apabila performa model pada data validasi stagnan dalam durasi yang ditentukan (misalnya lima epoch). Hal ini dilakukan untuk menjaga keseimbangan performa model dan mencegah overfitting yang dapat menurunkan akurasi pada data baru.

2. *Callback ModelCheckpoint*

Callback kedua yang digunakan adalah *ModelCheckpoint*. *Callback* ini secara otomatis menyimpan model setiap kali terjadi peningkatan pada nilai *validation accuracy* (*val_accuracy*) selama proses pelatihan. *ModelCheckpoint* memastikan bahwa model terbaik yang dihasilkan selama pelatihan disimpan, sehingga dapat digunakan tanpa harus melakukan pelatihan ulang jika performa model menurun pada *epoch-epoch* berikutnya.

FastAI menyediakan berbagai fungsi *callback*, termasuk *EarlyStopping* dan *ModelCheckpoint*, yang memungkinkan pelacakan dan pemantauan performa metrik selama pelatihan. Dengan menggunakan kedua *callback* ini, proses pelatihan dapat dijalankan secara lebih efisien. Sehingga memungkinkan penelitian ini mencapai hasil yang lebih baik dalam waktu yang lebih singkat dan dengan performa yang optimal.

Evaluasi Model

"Tahap evaluasi diaplikasikan guna menguji efektivitas arsitektur CNN ResNet101 dalam mengategorikan tiga varian penyakit pada daun padi. Langkah ini krusial untuk mengukur sejauh mana model mampu mengidentifikasi karakteristik visual khas dari setiap jenis penyakit secara akurat dan mengelompokkan citra sesuai dengan kelas yang benar, dengan menggunakan beberapa metrik evaluasi sebagai berikut:

1. Akurasi, yaitu metrik yang mengukur persentase prediksi yang benar dibandingkan dengan keseluruhan prediksi yang dihasilkan oleh model.
2. Presisi, yang menunjukkan tingkat ketepatan prediksi positif terhadap seluruh hasil prediksi positif yang dilakukan model.
3. Recall, yang mengukur kemampuan model dalam mengidentifikasi seluruh data relevan secara benar.
4. F1-Score, yaitu nilai rata-rata harmonis antara presisi dan recall yang memberikan gambaran performa model secara lebih seimbang.

HASIL DAN PEMBAHASAN


Penelitian ini memiliki hasil dan pembahasan yang diperoleh berdasarkan rancangan arsitektur model yang dikembangkan untuk mengklasifikasikan penyakit pada daun padi.

Tahap awal yang dilakukan adalah pembagian dataset (data splitting) ke dalam dua bagian, yaitu data latih (training) dan data validasi (validation) dengan rasio masing-masing sebesar 70% dan 30%, sebagaimana disajikan pada Tabel 1.

Selanjutnya, akan dilakukan proses augmentasi data latih dengan parameter yang sudah ditentukan yaitu rotasi, zoom, dan flipping horizontal, guna memperkaya variabilitas dataset. Proses augmentasi dimulai dengan merotasikan gambar menggunakan fungsi `rotate_image`, dimana sudut rotasi akan ditentukan oleh parameter yang mana penulis memilih untuk menggunakan sudut sebesar 20 derajat yang selanjutnya dikonversi ke radian untuk memanfaatkan fungsi trigonometri milik TensorFlow seperti cosine dan sine. Proses augmentasi kedua yang menggunakan parameter zoom dengan function `zoom_factor` untuk menentukan seberapa besar bagian pada citra yang akan dipertahankan. Fungsi ini akan memotong area tengah yang dihitung secara simetris dari citra asli yang kemudian akan dimasukkan ke dalam array baru. Proses augmentasi terakhir menggunakan fungsi `flip_image` yang memanfaatkan slicing untuk membalik urutan kolom pada citra jika parameter tersebut diisi dengan nilai True. Selain diperlakukan proses augmentasi, citra akan melalui proses perubahan ukuran (`resize`) menjadi $224 * 224$.

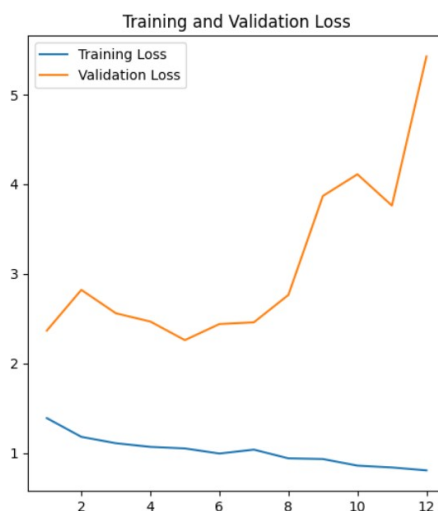
Selanjutnya, penelitian ini menerapkan dua fungsi callback. Callback pertama adalah `EarlyStopping`, yang berfungsi untuk menghentikan proses pelatihan model apabila nilai metrik validation loss (`val_loss`) tidak mengalami perbaikan selama tujuh iterasi pelatihan berturut-turut. Callback kedua adalah `ModelCheckpoint`, yang digunakan untuk menyimpan model ke dalam berkas setiap kali terjadi peningkatan nilai validation accuracy (`val_accuracy`) selama proses pelatihan. Proses pelatihan dilakukan selama 30 epoch dengan ukuran batch sebesar 64, di mana data pelatihan dibagi ke dalam beberapa batch kecil dan bobot model diperbarui setiap kali satu batch selesai diproses.

Gambar 4 menampilkan grafik training accuracy dan validation accuracy yang diperoleh setelah proses pelatihan model selama 30 epoch. Sumbu horizontal menunjukkan jumlah epoch pelatihan, sedangkan sumbu vertikal merepresentasikan nilai akurasi dalam rentang 0 hingga 1. Berdasarkan Gambar 4, nilai validation accuracy tertinggi dicapai pada rentang epoch ke-8 hingga ke-12 dengan nilai akurasi sebesar 33,33%. Nilai tersebut cenderung stagnan, yang mengindikasikan bahwa model belum mampu melakukan generalisasi secara optimal terhadap data yang tidak digunakan pada tahap pelatihan.



Gambar 4. Grafik Nilai Accuracy pada Model

Sumber: Data Diolah

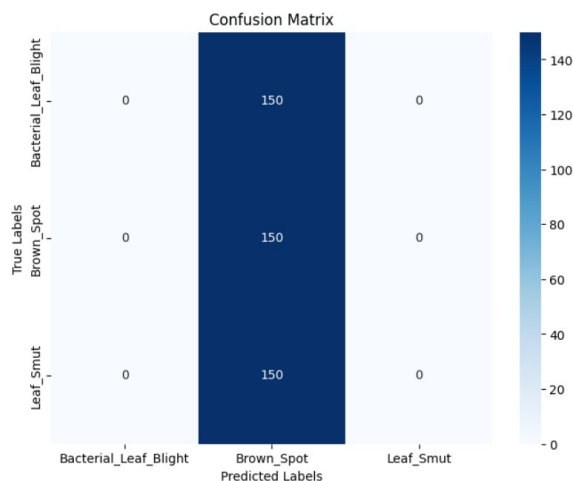


Gambar 5. Grafik Nilai Loss pada Model

Sumber: Data Diolah

Gambar 5 menampilkan grafik nilai loss selama proses pelatihan model, di mana sumbu horizontal menunjukkan jumlah epoch yang telah dilalui, sedangkan sumbu vertikal merepresentasikan nilai loss model dengan rentang antara 1 hingga 5. Berdasarkan Gambar 5, nilai validation loss tertinggi terjadi pada epoch ke-12 dengan nilai sekitar 5,4%.

Guna menilai ketepatan klasifikasi, model dievaluasi menggunakan confusion matrix. Rincian mengenai kemampuan model dalam memprediksi kelas secara akurat disajikan pada Gambar 6.



Gambar 6. Hasil Evaluasi *Confusion Matrix*

Sumber: Data Diolah

Berdasarkan Gambar 6. menunjukkan bahwa model memiliki akurasi yang rendah dalam memprediksi kelas *bacterial leaf blight* dan *leaf smut* dengan nilai *precision* dan *recall* yang mendekati 0, yang mengindikasikan bahwa model sering salah dalam memprediksi kedua kelas tersebut. Sebaliknya, untuk kelas *brown spot*, model memiliki *recall* yang sangat

baik 1.00, tetapi *precision*-nya relatif rendah, yang mengindikasikan bahwa meskipun model memprediksi kelas ini dengan benar sebagian besar waktu, ada juga banyak kesalahan dalam prediksi kelas ini.

```
Classification Report:

```

	precision	recall	f1-score	support
Bacterial_Leaf_Blight	0.00	0.00	0.00	150
Brown_Spot	0.33	1.00	0.50	150
Leaf_Smut	0.00	0.00	0.00	150
accuracy			0.33	450
macro avg	0.11	0.33	0.17	450
weighted avg	0.11	0.33	0.17	450

Gambar 7. Classification report

Sumber: Data Diolah

Hasil evaluasi model menggunakan classification report ditunjukkan pada Gambar 7. Berdasarkan hasil tersebut, diperoleh nilai akurasi tertinggi model selama proses pelatihan sebesar 0,33. Akurasi merepresentasikan proporsi prediksi yang benar terhadap keseluruhan citra dalam dataset, di mana nilai akurasi mendekati 1 menunjukkan kinerja model yang baik, sedangkan nilai yang mendekati 0 mengindikasikan performa model yang rendah.

Selain akurasi, metrik lain yang digunakan untuk menilai performa model meliputi presisi, recall, dan F1-score. Hasil classification report menunjukkan bahwa kelas Brown Spot memiliki nilai recall sempurna, sementara kelas Bacterial Leaf Blight dan Leaf Smut masing-masing menunjukkan nilai recall sebesar 0.

SIMPULAN

Implementasi metode CNN dengan model ResNet101 pada klasifikasi penyakit daun padi menghasilkan akurasi yang cukup baik, sekitar 33,33%. Proses augmentasi data yang dilakukan dengan rotasi, zoom, dan flipping horizontal terbukti efektif dalam meningkatkan variasi data dan membantu model mengatasi masalah ketidakseimbangan kelas. Evaluasi model menggunakan metrik seperti akurasi, precision, recall, dan f1-score menunjukkan hasil yang bervariasi antar kelas. Kelas brown spot memiliki kinerja terbaik dengan nilai recall sebesar 1.00, namun precision-nya relatif rendah. Sebaliknya, kelas bacterial leaf blight dan leaf smut menunjukkan kinerja yang buruk yang ditunjukkan dengan precision dan recall yang mendekati 0, menandakan bahwa model kesulitan dalam mengklasifikasikan kedua kelas tersebut dengan akurat. Meskipun akurasi model masih terbatas, hasil ini menunjukkan bahwa model CNN dengan arsitektur ResNet101 dapat dijadikan dasar untuk penelitian lebih lanjut dalam klasifikasi penyakit tanaman, dengan perbaikan lebih lanjut pada pemrosesan data dan tuning hyperparameter. Penelitian selanjutnya dapat fokus pada penggunaan dataset yang lebih seimbang atau penerapan teknik lain untuk menangani masalah overfitting dan meningkatkan kinerja model pada kelas yang lebih sulit dikenali.

DAFTAR PUSTAKA

Andikayani, R., Khaldun, R. I., Hafid, A., & Asmira, A. (2023). Analisis Perdagangan Internasional Indonesia dengan Papua Nugini di Bidang Pertanian Tahun 2019-2021. Indonesian Journal of Peace and Security Studies (IJPSS), 5(1), 1-11.

- Oktaviana, U. N., Hendrawan, R., Annas, A. D. K., & Wicaksono, G. W. (2021). Klasifikasi penyakit padi berdasarkan citra daun menggunakan model terlatih resnet101. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(6), 1216-1222.
- Khan, M. A., Akram, T., Sharif, M., Javed, M. Y., & Saba, T. (2021). An integrated framework of deep learning and artificial intelligence for rice disease detection. *Sensors*, 21(5), 1851.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.
- Putra, B., Nugroho, B., & Anggraeny, F. (2021). Penggunaan lift pada gedung-Gedu deteksi Dan Menghitung manusia Menggunakan Yolo-CNN. *Jurnal Informatika Dan Sistem Informasi*, 2(1), 67-76.
- Nawaz, S., Rasheed, S., Sami, W., Hussain, L., Aldweesh, A., Salaria, U. A., & Khan, M. S. (2023). Deep Learning ResNet101 Deep Features of Portable Chest X-Ray Accurately Classify COVID-19 Lung Infection. *Computers, Materials & Continua*, 75(3).
- Rahman, C. R., Arko, P. S., Ali, M. E., Khan, M. A. I., Apon, S. H., Nowrin, F., & Wasif, A. (2020). Identification and recognition of rice diseases and pests using convolutional neural networks. *Biosystems Engineering*, 194, 112-120.
- Islam, M. A., Shuvo, M. N. R., Shamsojjaman, M., Hasan, S., Hossain, M. S., & Khatun, T. (2021). An automated convolutional neural network based approach for paddy leaf disease detection. *International Journal of Advanced Computer Science and Applications*, 12(1).
- Sagar, A. and Jacob, D. (2021) 'On Using Transfer Learning For Plant Disease Detection Deep learning View project On Using Transfer Learning For Plant Disease Detection'. Available at: <https://www.researchgate.net/publication/342492871>.
- Ramesh, S. and Vydeki, D. (2019) 'Application of machine learning in detection of blast disease in south indian rice crops', *Journal of Phytology*, 11, pp. 31-37. Available at: <https://doi.org/10.25081/jp.2019.v11.5476>.