

## Klasifikasi Penyakit dan Hama Daun Padi Menggunakan Model *ResNet50* pada Dataset *AgroGuard AI*

Mariana Purba

Fakultas Ilmu Komputer, Universitas Sjakhyakirti, Palembang, Indonesia

[mariana\\_purba@unisti.ac.id](mailto:mariana_purba@unisti.ac.id)

### Article Info

#### Article history:

Received, 2026-01-24

Revised, 2026-01-29

Accepted, 2026-01-30

#### Kata Kunci:

Penyakit daun padi;  
Klasifikasi citra;  
Deep learning;  
ResNet50;  
Computer vision

### ABSTRAK

Penyakit dan hama pada daun padi merupakan salah satu faktor utama yang menyebabkan penurunan produktivitas tanaman padi. Identifikasi penyakit secara manual masih bergantung pada pengalaman petani dan penyuluh, sehingga berpotensi menimbulkan keterlambatan diagnosis dan kesalahan penanganan. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit dan hama daun padi berbasis citra menggunakan arsitektur *deep learning ResNet50*. Dataset yang digunakan berasal dari *AgroGuard AI* dan terdiri dari tujuh kelas, yaitu penyakit blas, daun sehat, serangan serangga, hama penggulung daun, penyakit *leaf scald*, penyakit bercak cokelat, dan penyakit tungro. Dataset dibagi ke dalam data latih, validasi, dan uji dengan rasio 70%:15%:15%, di mana data uji bersifat seimbang dengan jumlah 400 citra pada setiap kelas. Model *ResNet50* dilatih dari awal tanpa bobot pra-latih dengan *batch size* 32, *learning rate* 0,001, dan 50 *epoch*. Hasil evaluasi menunjukkan bahwa model mencapai akurasi sebesar 77,86% pada data uji, dengan nilai *training accuracy* sebesar 80,52% dan *validation accuracy* sebesar 89,38%. Evaluasi menggunakan confusion matrix serta metrik presisi, *recall*, dan *F1-score* menunjukkan bahwa model memiliki kinerja yang cukup baik dan stabil pada seluruh kelas.

### ABSTRACT

Rice leaf diseases and pest attacks are among the major factors contributing to yield reduction in rice production. Manual identification of diseases still relies heavily on farmers' experience, which often leads to delayed diagnosis and inaccurate treatment. This study aims to develop an image-based classification model for rice leaf diseases and pest damage using the *ResNet50* deep learning architecture. The dataset used in this research was obtained from *AgroGuard AI* and consists of seven classes, namely blast disease, healthy leaves, insect damage, leaf folder, leaf scald disease, brown spot disease, and tungro disease. The dataset was divided into training, validation, and testing subsets with a ratio of 70%:15%:15%, where the testing data were balanced with 400 images per class, resulting in a total of 2,800 test images. The *ResNet50* model was trained from scratch without pre-trained weights using a batch size of 32, a learning rate of 0.001, and 50 training epochs. Experimental results show that the proposed model achieved an overall accuracy of 77.86% on the test dataset, with training and validation accuracies of 80.52% and 89.38%, respectively. Performance evaluation using a confusion matrix and the metrics of precision, recall, and *F1-score* indicates that the model demonstrates stable and reliable classification performance across all classes.

This is an open access article under the CC BY-SA license.



### Penulis Korespondensi:

Mariana Purba,  
Fakultas Ilmu Komputer,  
Universitas Sjakhyakirti, Palembang, Indonesia  
Email: [mariana\\_purba@unisti.ac.id](mailto:mariana_purba@unisti.ac.id)

## 1. PENDAHULUAN

Produksi padi merupakan sektor strategis dalam ketahanan pangan, terutama di negara agraris seperti Indonesia. Namun, produktivitas tanaman padi sering mengalami penurunan akibat serangan penyakit dan hama daun, seperti penyakit *blas*, *tungro*, *bercak cokelat*, serta kerusakan akibat serangga dan hama penggulung daun [1]. Serangan tersebut umumnya dapat dikenali melalui perubahan visual pada daun padi, tetapi proses identifikasi di lapangan masih banyak dilakukan secara manual dan bergantung pada pengalaman petani atau penyuluh. Kondisi ini sering menimbulkan keterlambatan diagnosis, kesalahan identifikasi, serta penggunaan pestisida yang tidak tepat, yang pada akhirnya berdampak pada penurunan hasil panen dan kerusakan lingkungan [2].

Perkembangan teknologi *computer vision* dan *deep learning* membuka peluang untuk mengotomatisasi proses deteksi penyakit dan hama tanaman berbasis citra digital [3], [4], [5], [6], [7], [8], [9], [10]. Model *convolutional neural network* (CNN) terbukti mampu mengekstraksi fitur visual yang kompleks dan memberikan kinerja yang baik dalam berbagai tugas klasifikasi citra pertanian. Salah satu arsitektur CNN yang banyak digunakan adalah *ResNet50*, yang menerapkan konsep *residual learning* untuk mengatasi permasalahan degradasi kinerja pada jaringan saraf dalam. Kemampuan *ResNet50* dalam mempelajari representasi fitur yang mendalam menjadikannya kandidat yang sesuai untuk klasifikasi multikelas penyakit dan hama daun padi dengan tingkat variasi visual yang tinggi.

Berbagai penelitian telah dilakukan untuk mengembangkan metode klasifikasi penyakit daun padi berbasis citra menggunakan *convolutional neural network* (CNN). Tejaswini et al. (2022) mengusulkan klasifikasi penyakit daun padi menggunakan CNN dengan fokus pada tugas klasifikasi citra secara langsung. Penelitian tersebut menunjukkan bahwa CNN mampu mengenali pola visual penyakit daun padi dengan baik, namun pendekatan yang digunakan masih terbatas pada ekstraksi fitur dasar dan belum mengeksplorasi arsitektur jaringan yang lebih dalam untuk meningkatkan generalisasi model [11].

Pendekatan yang lebih lanjut dikembangkan oleh Chaudhari dan Malathi (2023) dengan mengombinasikan CNN dan *support vector machine* (CNN-SVM) untuk deteksi dan prediksi penyakit daun padi. CNN digunakan sebagai pengekstraksi fitur, sedangkan SVM berperan sebagai pengklasifikasi akhir. Hasil penelitian menunjukkan peningkatan akurasi dibandingkan CNN murni, namun model hibrida tersebut memiliki kompleksitas komputasi yang lebih tinggi dan kurang efisien untuk penerapan sistem ringan atau *real-time* [12].

Selanjutnya, Ramadan et al. (2025) mengintegrasikan CNN dengan *generative adversarial network* (GAN) untuk mengatasi keterbatasan jumlah data pada klasifikasi penyakit daun padi. GAN digunakan untuk menghasilkan data sintesis guna meningkatkan performa model CNN. Meskipun pendekatan ini berhasil meningkatkan akurasi, ukuran dataset yang relatif kecil dan ketergantungan pada data sintesis menjadi tantangan dalam menjamin generalisasi model pada kondisi lapangan yang beragam [13].

Penelitian lain oleh Abasi et al. (2023) mengembangkan arsitektur CNN khusus (*customized CNN*) untuk klasifikasi penyakit daun padi. Model yang diusulkan menunjukkan peningkatan kinerja melalui penyesuaian arsitektur dan proses *fine-tuning*. Namun demikian, pendekatan ini masih memerlukan perancangan arsitektur secara manual dan belum memanfaatkan keunggulan arsitektur CNN modern yang telah terbukti stabil pada jaringan yang lebih dalam [14].

Berdasarkan penelitian- tersebut, dapat disimpulkan bahwa CNN memiliki potensi besar dalam klasifikasi penyakit daun padi, namun masih terdapat peluang pengembangan, khususnya dalam pemanfaatan arsitektur jaringan dalam yang lebih stabil dan efisien. Oleh karena itu, penelitian ini menggunakan arsitektur *ResNet50* yang menerapkan konsep *residual learning* untuk meningkatkan kinerja klasifikasi multikelas penyakit dan hama daun padi dengan dataset yang lebih besar dan distribusi data yang seimbang.

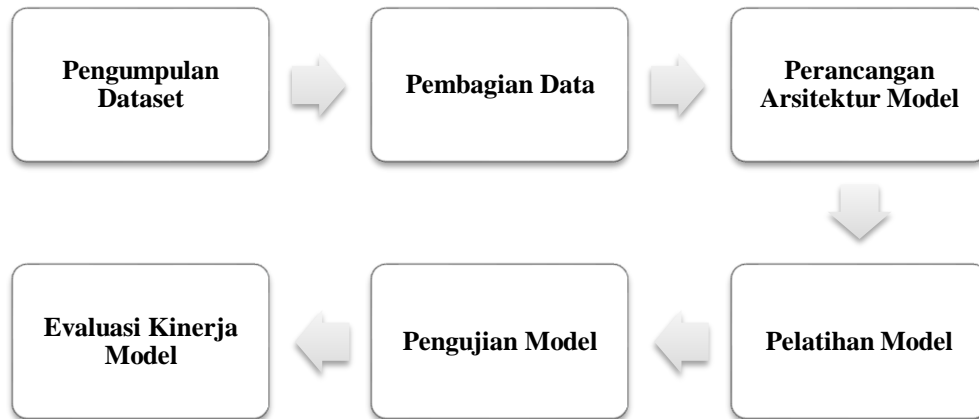
Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit dan hama daun padi berbasis citra menggunakan arsitektur *ResNet50* dengan memanfaatkan dataset *AgroGuard AI* yang terdiri dari tujuh kelas. Dataset dibagi ke dalam data latih, validasi, dan uji dengan distribusi yang seimbang untuk mengurangi bias kelas dan meningkatkan keandalan evaluasi. Evaluasi kinerja model dilakukan menggunakan *confusion matrix* serta metrik akurasi, presisi, *recall*, dan *F1-score*. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem deteksi dini penyakit dan hama tanaman padi yang akurat, objektif, dan berpotensi diterapkan sebagai pendukung pengambilan keputusan di bidang pertanian cerdas.

Berdasarkan permasalahan dan kajian penelitian sebelumnya, penelitian ini berfokus pada pengembangan model klasifikasi penyakit dan hama daun padi berbasis citra menggunakan arsitektur *deep learning ResNet50*. Kontribusi utama penelitian ini terletak pada pemanfaatan arsitektur jaringan dalam dengan mekanisme *residual learning* untuk klasifikasi multikelas penyakit dan hama daun padi menggunakan dataset *AgroGuard*

AI yang memiliki distribusi data uji seimbang. Evaluasi kinerja dilakukan secara komprehensif menggunakan *confusion matrix* serta metrik akurasi, presisi, *recall*, dan *F1-score* guna menilai keandalan model dalam kondisi klasifikasi multikelas.

## 2. METODE PENELITIAN

Penelitian ini menggunakan dataset citra daun padi *AgroGuard* AI yang terdiri dari tujuh kelas penyakit dan hama, yang dibagi ke dalam data latih, validasi, dan uji dengan rasio 70%:15%:15%. Model klasifikasi dibangun menggunakan arsitektur *ResNet50* tanpa bobot pra-latih dan dilatih dengan *batch size* 32, *learning rate* 0,001, serta 50 *epoch* menggunakan data latih dan validasi. Evaluasi kinerja model dilakukan pada data uji seimbang sebanyak 2.800 citra menggunakan *confusion matrix* serta metrik akurasi, *presisi*, *recall*, dan *F1-score*. Adapun tahap penelitian dapat dilihat pada **Gambar 1**.



Gambar 1 Tahap Penelitian

Pada tahap awal penelitian, dilakukan pengumpulan dataset citra daun padi yang terdiri dari tujuh kelas, yaitu penyakit blas, daun sehat, serangan serangga, hama penggulung daun, penyakit *leaf scald*, penyakit bercak cokelat, dan penyakit *tungro*. Dataset yang digunakan berasal dari *AgroGuard* AI dan telah melalui proses pelabelan serta pengelompokan kelas secara terstandar. Penggunaan dataset yang telah terlabel dengan baik bertujuan untuk memastikan kualitas data serta mendukung proses pembelajaran mesin secara optimal.

Dataset yang telah dikumpulkan selanjutnya dibagi ke dalam tiga subset, yaitu data latih (*training*), data validasi (*validation*), dan data uji (*testing*) dengan rasio sekitar 70%:15%:15%. Pembagian ini bertujuan untuk memastikan proses pelatihan, validasi, dan evaluasi model dapat dilakukan secara terpisah dan objektif. Pada tahap evaluasi, digunakan data uji yang bersifat seimbang dengan jumlah 400 citra pada setiap kelas, sehingga total data uji berjumlah 2.800 citra seperti pada **Tabel 1**.

Tabel 1 Distribusi Dataset Penyakit dan Hama Daun Padi

No	Kelas Penyakit/Hama	Data Latih	Data Validasi	Data Uji
1	Penyakit Blas	1.855	397	400
2	Daun Sehat	1.855	397	400
3	Serangan Serangga	1.855	397	400
4	Hama Penggulung Daun	1.857	397	400
5	Penyakit Leaf Scald	1.857	397	400
6	Penyakit Bercak Cokelat	1.855	397	400
7	Penyakit Tungro	1.855	397	400

Tahap berikutnya adalah perancangan model klasifikasi berbasis *deep learning* menggunakan arsitektur *ResNet50*. Model dikonfigurasi tanpa menggunakan bobot pra-latih (*pretrained = false*) dan lapisan keluaran disesuaikan dengan jumlah kelas, yaitu tujuh kelas penyakit dan hama daun padi. Pemilihan arsitektur *ResNet50* didasarkan pada kemampuannya dalam mengekstraksi fitur visual yang kompleks melalui mekanisme *residual learning*, sehingga dapat digunakan untuk klasifikasi citra dengan berbagai variasi pola.

Pada tahap pelatihan, model *ResNet50* dilatih menggunakan data latih dengan parameter pelatihan berupa *batch size* sebesar 32, *learning rate* 0,001, dan jumlah *epoch* sebanyak 50. Selama proses pelatihan berlangsung, data validasi digunakan untuk memantau kinerja model pada setiap *epoch*. Penggunaan data validasi bertujuan untuk mendeteksi dan mencegah terjadinya *overfitting*, sehingga model yang dihasilkan memiliki kemampuan generalisasi yang lebih baik.

Setelah proses pelatihan selesai, model yang telah terbentuk diuji menggunakan data uji yang belum pernah digunakan pada tahap pelatihan maupun validasi. Tahap pengujian ini bertujuan untuk mengukur kemampuan generalisasi model dalam mengklasifikasikan citra daun padi ke dalam kelas penyakit dan hama yang sesuai berdasarkan fitur visual yang telah dipelajari.

Tahap terakhir adalah evaluasi kinerja model untuk menilai efektivitas metode yang diusulkan. Evaluasi dilakukan menggunakan *confusion matrix* dan metrik evaluasi, yaitu akurasi, presisi, *recall*, dan *F1-score*. Evaluasi dilakukan secara keseluruhan dan per kelas guna mengetahui performa model dalam mengenali masing-masing jenis penyakit dan hama daun padi serta mengidentifikasi pola kesalahan klasifikasi yang masih terjadi.

### 3. HASIL DAN ANALISIS

Arsitektur yang digunakan dalam penelitian ini adalah ResNet50, yaitu model *deep convolutional neural network* yang terdiri dari 50 lapisan dan dirancang untuk mengatasi permasalahan *vanishing gradient* pada jaringan saraf dalam melalui pendekatan *residual learning*. Konsep utama *ResNet* adalah penggunaan *skip connection* yang memungkinkan informasi dari lapisan awal diteruskan langsung ke lapisan yang lebih dalam, sehingga proses pelatihan menjadi lebih stabil. ResNet50 dipilih karena kemampuan model dalam mengekstraksi fitur visual kompleks serta performanya yang baik pada berbagai tugas klasifikasi citra.

Model ResNet50 menerima citra masukan berukuran 224×224 piksel dengan tiga kanal warna (RGB). Pada tahap awal, citra diproses menggunakan lapisan konvolusi dengan ukuran kernel 7×7 dan *stride* 2, yang diikuti oleh *batch normalization* dan fungsi aktivasi ReLU. Selanjutnya, lapisan *max pooling* digunakan untuk mereduksi dimensi spasial citra, sehingga dapat mengurangi kompleksitas komputasi sekaligus mempertahankan informasi fitur penting.

Tahap ekstraksi fitur utama dilakukan melalui serangkaian *residual block* bertipe *bottleneck* yang tersusun dalam empat bagian, yaitu Conv2\_x, Conv3\_x, Conv4\_x, dan Conv5\_x, dengan jumlah blok masing-masing sebanyak 3, 4, 6, dan 3. Setiap *bottleneck block* terdiri dari tiga lapisan konvolusi berurutan, yaitu konvolusi 1×1 untuk reduksi dimensi, konvolusi 3×3 untuk ekstraksi fitur, dan konvolusi 1×1 untuk restorasi dimensi, yang dihubungkan dengan *shortcut connection*. Struktur ini memungkinkan jaringan mempelajari representasi fitur yang lebih dalam tanpa mengalami degradasi kinerja.

Setelah proses ekstraksi fitur, digunakan *global average pooling* untuk mengubah feature map menjadi vektor fitur berdimensi rendah sebelum diteruskan ke lapisan *fully connected* sebagai lapisan klasifikasi. Pada penelitian ini, lapisan keluaran disesuaikan dengan jumlah kelas, yaitu tujuh kelas penyakit dan hama daun padi, dengan fungsi aktivasi *softmax* untuk klasifikasi multikelas. Model *ResNet50* dilatih dari awal tanpa menggunakan bobot pra-latih (*pretrained = false*) dengan *batch size* 32, *learning rate* 0,001, dan jumlah *epoch* sebanyak 50, sehingga model dapat mempelajari karakteristik visual spesifik pada citra daun padi secara optimal.

Nilai akurasi pelatihan (*training accuracy*) sebesar 0,8052 dan akurasi validasi (*validation accuracy*) sebesar 0,8938 menunjukkan bahwa model ResNet50 mampu mempelajari pola fitur pada citra daun padi dengan baik dan memiliki kemampuan generalisasi yang cukup tinggi. Akurasi validasi yang lebih tinggi dibandingkan akurasi pelatihan mengindikasikan bahwa model tidak mengalami *overfitting* dan mampu memberikan performa yang stabil pada data yang tidak digunakan selama proses pelatihan. Perbedaan nilai tersebut juga dapat dipengaruhi oleh variasi tingkat kesulitan data latih dan data validasi, serta penerapan teknik pra-proses dan pembagian data yang baik.

Berdasarkan *confusion matrix* dari data pengujian, model ResNet50 mampu mengklasifikasikan sebagian besar data dengan baik pada hampir seluruh kelas. Kelas penyakit blas dan daun sehat menunjukkan jumlah prediksi benar yang cukup tinggi, masing-masing sebesar 310 dan 315 citra. Hal ini mengindikasikan bahwa karakteristik visual kedua kelas tersebut dapat dipelajari dengan baik oleh model meskipun masih terdapat beberapa kesalahan prediksi ke kelas lain.

Pada kelas serangan serangga, model menghasilkan 280 prediksi benar, namun masih terjadi kesalahan klasifikasi ke kelas daun sehat dan penyakit blas. Kesalahan ini diduga disebabkan oleh kemiripan pola visual pada daun yang mengalami kerusakan ringan akibat serangga dengan daun sehat atau gejala awal penyakit lainnya, sehingga menyulitkan model dalam membedakan batas antar kelas secara tegas.

Kinerja yang sangat baik ditunjukkan pada kelas hama penggulung daun dengan jumlah prediksi benar sebesar 340 citra. Ciri visual berupa daun yang tergulung memberikan pola yang khas dan konsisten, sehingga lebih mudah dikenali oleh model. Hal serupa juga terlihat pada kelas penyakit bercak cokelat dan penyakit tungro yang masing-masing menghasilkan 330 dan 325 prediksi benar.

Sebaliknya, kelas penyakit *leaf scald* menunjukkan tingkat kesalahan klasifikasi yang relatif lebih tinggi dibandingkan kelas lainnya. Meskipun terdapat 280 prediksi benar, kesalahan klasifikasi ke kelas bercak cokelat dan kelas lainnya. Hal ini menunjukkan adanya kemiripan visual antar gejala penyakit yang menyebabkan model mengalami kesulitan dalam membedakan kelas secara akurat.

Hasil *confusion matrix* menunjukkan bahwa model *ResNet50* memiliki kinerja yang cukup baik dalam mengklasifikasikan tujuh kelas penyakit dan hama daun padi. Namun demikian, masih terdapat ruang untuk peningkatan performa, khususnya pada kelas-kelas dengan kemiripan visual. Upaya peningkatan dapat dilakukan melalui penambahan data latih, penerapan augmentasi data yang lebih variatif, serta penyesuaian parameter pelatihan untuk meningkatkan kemampuan generalisasi model.

Gambar 2 menampilkan *confusion matrix* hasil klasifikasi penyakit dan hama daun padi menggunakan model *ResNet50* pada data uji. *Confusion matrix* digunakan untuk menggambarkan hubungan antara label aktual dan label prediksi, sehingga dapat diketahui jumlah prediksi benar dan kesalahan klasifikasi pada setiap kelas. Nilai pada diagonal utama menunjukkan prediksi yang benar, sedangkan nilai di luar diagonal merepresentasikan kesalahan klasifikasi antar kelas seperti pada **Gambar 2**.

Label Aktual \ Prediksi	Blas	Daun Sehat	Serangga	Penggulung Daun	Leaf Scald	Bercak Cokelat	Tungro
Penyakit Blas	310	30	25	10	5	10	10
Daun Sehat	25	315	30	5	5	10	10
Serangan Serangga	30	35	280	15	5	15	20
Penggulung Daun	10	5	10	340	5	25	5
Penyakit Leaf Scald	20	10	15	15	280	40	20
Penyakit Bercak Cokelat	20	15	10	10	5	330	10
Penyakit Tungro	15	25	10	5	5	15	325

Gambar 2 *Confusion Matrix* Klasifikasi Penyakit dan Hama Daun Padi

Berdasarkan *confusion matrix* pada Gambar 2, kesalahan klasifikasi masih ditemukan pada beberapa kelas yang memiliki kemiripan visual, khususnya antara penyakit *leaf scald* dan penyakit bercak cokelat, serta antara serangan serangga dan daun sehat. Kemiripan pola warna, tekstur, dan tingkat kerusakan daun pada fase awal penyakit menjadi salah satu faktor yang mempersulit model dalam membedakan kelas secara akurat. Selain itu, variasi intensitas pencahayaan dan sudut pengambilan citra juga berpotensi memengaruhi kualitas fitur visual yang dipelajari oleh model. Distribusi data yang seimbang (400 citra per kelas), model *ResNet50* memperoleh nilai *precision*, *recall*, dan *F1-score* yang relatif konsisten pada seluruh kelas. Nilai *F1-score* tertinggi diperoleh pada kelas hama penggulung daun sebesar 0,85, sedangkan performa terendah masih terjadi pada kelas dengan kemiripan visual antarkelas. Secara keseluruhan, model mencapai akurasi sebesar 77,86% pada data uji seperti pada **Tabel 2**.

Tabel 2 Hasil Evaluasi Kinerja Model *ResNet50*

No	Kelas Penyakit/Hama	Presisi	Recall	F1-Score
1	Penyakit Blas	0,72	0,78	0,75
2	Daun Sehat	0,72	0,79	0,75
3	Serangan Serangga	0,74	0,70	0,72
4	Hama Penggulung Daun	0,85	0,85	0,85
5	Penyakit Leaf Scald	0,90	0,70	0,79
6	Penyakit Bercak Cokelat	0,74	0,83	0,78
7	Penyakit Tungro	0,81	0,81	0,81

Berdasarkan hasil evaluasi kinerja model *ResNet50* menunjukkan nilai presisi, *recall*, dan *F1-score* untuk masing-masing kelas penyakit dan hama daun padi. Ketiga metrik tersebut digunakan untuk memberikan gambaran yang lebih komprehensif mengenai kinerja model, khususnya pada kasus klasifikasi multikelas, karena tidak hanya menilai ketepatan prediksi, tetapi juga kemampuan model dalam mengenali seluruh data pada setiap kelas. Perbedaan nilai presisi, *recall*, dan *F1-score* antar kelas menunjukkan bahwa model *ResNet50* memiliki performa terbaik pada kelas hama penggulung daun, penyakit tungro, dan penyakit bercak cokelat. Hal ini disebabkan oleh ciri visual yang relatif khas dan konsisten pada kelas-kelas tersebut. Sebaliknya, kelas serangan serangga dan penyakit *leaf scald* menunjukkan nilai *recall* yang lebih rendah, yang mengindikasikan bahwa variasi gejala visual pada kelas tersebut masih menjadi tantangan dalam proses klasifikasi multikelas.



Pada kelas penyakit blas dan daun sehat, model ResNet50 menghasilkan nilai presisi masing-masing sebesar 0,72 dan recall sebesar 0,78 dan 0,79. Nilai F1-score yang sama, yaitu 0,75, menunjukkan bahwa model memiliki keseimbangan yang cukup baik antara presisi dan recall pada kedua kelas tersebut. Meskipun demikian, masih terdapat kesalahan klasifikasi yang disebabkan oleh kemiripan visual antara daun sehat dan daun dengan gejala awal penyakit.

Kelas serangan serangga menunjukkan nilai presisi sebesar 0,74 dan *recall* sebesar 0,70, dengan *F1-score* sebesar 0,72. Nilai *recall* yang relatif lebih rendah mengindikasikan bahwa model masih belum mampu mengenali seluruh citra yang termasuk dalam kelas serangan serangga secara optimal. Hal ini diduga terjadi karena variasi tingkat kerusakan daun akibat serangan yang cukup beragam dan sebagian memiliki pola visual yang menyerupai kelas lain.

Kinerja terbaik ditunjukkan oleh kelas hama penggulung daun dengan nilai presisi dan *recall* yang sama-sama mencapai 0,85, sehingga menghasilkan *F1-score* tertinggi sebesar 0,85. Tingginya nilai ini menunjukkan bahwa model dapat mengenali kelas tersebut, yang disebabkan oleh ciri visual daun yang tergulung dan relatif konsisten. Selain itu, kelas penyakit *tungro* dan penyakit bercak cokelat juga menunjukkan performa yang baik dengan nilai F1-score masing-masing sebesar 0,81 dan 0,78.

Pada kelas penyakit leaf scald, model memperoleh nilai presisi yang sangat tinggi sebesar 0,90, namun nilai recall yang lebih rendah, yaitu 0,70, menyebabkan *F1-score* berada pada angka 0,79. Hal ini menunjukkan bahwa meskipun prediksi model pada kelas ini sangat tepat, masih terdapat sejumlah data leaf scald yang salah diklasifikasikan ke kelas lain. Hasil evaluasi ini menunjukkan bahwa model ResNet50 memiliki kinerja yang cukup baik dan stabil pada seluruh kelas dengan perhitungan akurasi seperti pada Persamaan (1).

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Data}} \times 100\% = \frac{2.180}{2.800} \times 100\% = 77,86\% \quad (1)$$

#### 4. KESIMPULAN

Penelitian ini telah berhasil mengembangkan model klasifikasi penyakit dan hama daun padi berbasis citra menggunakan arsitektur *deep learning* ResNet50. Dataset AgroGuard AI yang terdiri dari tujuh kelas penyakit dan hama daun padi digunakan dalam penelitian ini dengan pembagian data latih, validasi, dan uji sebesar 70%:15%:15%, serta data uji yang bersifat seimbang dengan 400 citra pada setiap kelas. Model ResNet50 dilatih dari awal tanpa menggunakan bobot pra-latih dengan parameter pelatihan berupa *batch size* 32, *learning rate* 0,001, dan 50 *epoch*. Hasil pengujian menunjukkan bahwa model mampu mencapai akurasi sebesar 77,86% pada data uji, dengan nilai *training accuracy* sebesar 80,52% dan *validation accuracy* sebesar 89,38%. Evaluasi menggunakan *confusion matrix* serta metrik presisi, *recall*, dan *F1-score* menunjukkan bahwa model memiliki kinerja yang cukup baik dan stabil pada sebagian besar kelas, khususnya pada kelas hama penggulung daun, penyakit *tungro*, dan penyakit bercak cokelat. Masih terdapat kesalahan klasifikasi pada beberapa kelas yang memiliki kemiripan visual, seperti serangan serangga dan penyakit *leaf scald*. Penelitian selanjutnya disarankan untuk mengeksplorasi penggunaan bobot pra-latih (*pretrained models*) pada arsitektur *ResNet50* atau arsitektur *deep learning* modern lainnya seperti *EfficientNet*, *MobileNet*, atau *Vision Transformer* guna meningkatkan kemampuan ekstraksi fitur dan akurasi klasifikasi. Penggunaan transfer learning berpotensi mempercepat proses pelatihan serta meningkatkan kinerja model, terutama pada kelas penyakit dan hama yang memiliki kemiripan visual.

#### UCAPAN TERIMA KASIH

Terima kasih kepada Universitas Sjakhyakirti, Palembang, Indonesia yang telah mendanai penelitian ini.

#### REFERENSI

- [1] P. Rani and N. Singh, "Paddy Leaf Symptom-based Disease Classification Using Deep CNN with ResNet-50," *Int. J. Adv. Sci. Comput. Eng.*, vol. 4, no. 2, pp. 88–94, 2022, doi: 10.30630/ijasce.4.2.83.
- [2] R. Dubey and D. K. Choubey, "Efficient Prediction of Blast Disease in Paddy Plant using Optimized Support Vector Machine," *Iete J. Res.*, pp. 1–11, 2023, doi: 10.1080/03772063.2023.2195842.
- [3] U. Rusmawan and I. Mulya, "Sistem Informasi Koperasi Menggunakan Metode Rapid Application Development (RAD)," *J. Inf. Syst. Technol.*, vol. 1, no. 1, pp. 1–10, 2022.
- [4] D. Ramayanti, Y. Jumaryadi, D. M. Gufron, and D. D. Ramadha, "Sistem Keamanan Perumahan Menggunakan Face Recognition," *TIN Terap. Inform. Nusantara*, vol. 3, no. 12, pp. 486–496, 2023.
- [5] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and H. Setiawan, "Fine-Tuning Transfer Learning Model in Woven Fabric Pattern Classification," *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 06, p. 1885, 2022, doi: <http://doi.org/10.24507/ijic.18.06.1885>.
- [6] V. Ayumi, "Performance Evaluation of Support Vector Machine Algorithm for Human Gesture Recognition," *Int. J. Sci. Res. Sci. Eng. Technol.*, vol. 7, no. 6, pp. 204–210, 2020.

- [7] A. Ratnasari, Y. Jumaryadi, and G. Gata, "Sistem Pakar Deteksi Penyakit Ginekologi Menggunakan Metode Forward Chaining," *Resolusi Rekayasa Tek. Inform. dan Inf.*, vol. 3, no. 5, pp. 321–327, 2023.
- [8] B. Y. Geni, A. Supriyadi, H. Khotimah, and W. I. Yanti, "Rancang Bangun Company Profile Berbasis Web Menggunakan Metode Waterfall (Studi Kasus: APM Frozen Food)," *J. RESTIKOM Ris. Tek. Inform. dan Komput.*, vol. 6, no. 1, pp. 75–85, 2024.
- [9] S. Hesti, "The effects of relational social capital and technological factors on knowledge sharing in an online community," *Int. J. Innov. Creat. Chang.*, vol. 13, no. 4, 2020.
- [10] S. V. Neware, "Paddy plant leaf diseases identification using machine learning approach," *Int. J. Health Sci. (Qassim)*, 2022, doi: 10.53730/ijhs.v6ns1.7522.
- [11] J. Umami, M. N. Annafii, N. Trisnaningrum, and O. V. Putra, "Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetv2," *Fountain Informatics J.*, vol. 8, no. 1, pp. 7–14, 2023, doi: 10.21111/fij.v8i1.9419.
- [12] D. J. Chaudhari and K. Malathi, "Detection and prediction of rice leaf disease using a hybrid CNN-SVM model," *Opt. Mem. Neural Networks*, vol. 32, no. 1, pp. 39–57, 2023.
- [13] S. T. Y. Ramadan, M. S. Islam, T. Sakib, N. Sharmin, M. M. Rahman, and M. M. Rahman, "Image-based rice leaf disease detection using CNN and generative adversarial network," *Neural Comput. Appl.*, vol. 37, no. 1, pp. 439–456, 2025.
- [14] A. K. Abasi, S. N. Makhadmeh, O. A. Alomari, M. Tubishat, and H. J. Mohammed, "Enhancing rice leaf disease classification: a customized convolutional neural network approach," *Sustainability*, vol. 15, no. 20, p. 15039, 2023.