

Pengenalan Penyakit Tanaman Berdasarkan Citra Daun Menggunakan Arsitektur *DenseNet* Berbasis Sekuensial

Mariana Purba

Fakultas Ilmu Komputer, Universitas Sjakhyakirti, Palembang, Indonesia

mariana_purba@unisti.ac.id

Article Info

Article history:

Received, 2026-01-24

Revised, 2026-01-29

Accepted, 2026-01-30

Kata Kunci:

penyakit tanaman;
citra daun;
deep learning;
DenseNet121;
klasifikasi citra

ABSTRAK

Penyakit tanaman yang menyerang daun dapat menurunkan kualitas dan produktivitas hasil pertanian, sehingga diperlukan metode deteksi yang akurat dan efisien. Penelitian ini bertujuan untuk mengembangkan model pengenalan penyakit tanaman berdasarkan citra daun menggunakan arsitektur *DenseNet121* berbasis sekuensial. Dataset yang digunakan terdiri dari 1.530 citra daun dengan tiga kelas, yaitu *healthy*, *powdery*, dan *rust*, yang dibagi ke dalam data latih, validasi, dan uji dengan distribusi yang relatif seimbang. Model dibangun dengan memanfaatkan *DenseNet121* sebagai base model dengan bobot *pre-trained ImageNet* dan seluruh layer dasar dibuat tidak dapat dilatih sebagai *feature extractor*. Proses klasifikasi dilakukan menggunakan lapisan *GlobalAveragePooling2D*, *Dense*, *Dropout*, dan *Softmax*. Hasil pelatihan menunjukkan bahwa model mencapai akurasi sebesar 98,28% pada data latih dan 96,25% pada data validasi. Evaluasi menggunakan data uji menghasilkan nilai akurasi sebesar 93,33%, yang menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dalam mengklasifikasikan penyakit tanaman berdasarkan citra daun. Hasil penelitian ini menunjukkan bahwa arsitektur *DenseNet* berbasis sekuensial dapat digunakan untuk pengenalan penyakit tanaman dan berpotensi dikembangkan sebagai sistem pendukung keputusan di bidang pertanian.

ABSTRACT

Keywords:

Plant disease;
leaf image;
deep learning;
DenseNet121;
image classification

Plant diseases that affect leaves can significantly reduce crop quality and productivity, making accurate and efficient detection methods essential. This study aims to develop a plant disease recognition model based on leaf images using a sequential DenseNet121 architecture. The dataset consists of 1,530 leaf images categorized into three classes: Healthy, Powdery, and Rust, which are divided into training, validation, and testing sets with a relatively balanced distribution. The model employs DenseNet121 as a base model with pre-trained ImageNet weights, where all base layers are frozen to function as a feature extractor. The classification process utilizes GlobalAverage Pooling2D, Dense, Dropout, and Softmax layers. Experimental results show that the model achieves an accuracy of 98.28% on the training data and 96.25% on the validation data. Evaluation on the test dataset yields an accuracy of 93.33%, indicating that the proposed model demonstrates good generalization capability in classifying plant diseases based on leaf images. These results suggest that the sequential DenseNet architecture is effective for plant disease recognition and has potential for further development as a decision support system in agriculture.

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*

1. PENDAHULUAN

Tanaman merupakan komoditas penting dalam sektor pertanian yang berperan besar dalam menjaga ketahanan pangan dan perekonomian. Namun, produktivitas tanaman sering mengalami penurunan akibat serangan penyakit yang umumnya muncul pada bagian daun. Penyakit tanaman seperti *powdery mildew* dan *rust* dapat menyebabkan kerusakan jaringan daun, menghambat proses fotosintesis, serta menurunkan kualitas dan kuantitas hasil panen. Oleh karena itu, diperlukan metode yang sesuai untuk melakukan pengenalan penyakit tanaman sejak dini [1], [2].

Identifikasi penyakit tanaman secara konvensional masih banyak dilakukan melalui pengamatan visual oleh petani atau pakar tanaman. Metode ini memiliki beberapa keterbatasan, antara lain bersifat subjektif, membutuhkan pengalaman khusus, serta kurang efisien ketika diterapkan pada skala besar. Selain itu, kemiripan gejala antarjenis penyakit sering menyebabkan kesalahan diagnosis. Kondisi tersebut mendorong perlunya pendekatan berbasis teknologi yang mampu melakukan pengenalan penyakit tanaman secara otomatis dan konsisten.

Perkembangan teknologi *computer vision* dan *deep learning* membuka peluang besar dalam pengolahan citra digital untuk klasifikasi penyakit tanaman [3], [4], [5], [6], [7], [8], [9], [10]. Salah satu pendekatan yang banyak digunakan adalah pemanfaatan citra daun sebagai sumber informasi visual karena daun merupakan bagian tanaman yang paling awal menunjukkan gejala penyakit. Dengan menggunakan citra daun, sistem dapat mempelajari pola warna, tekstur, dan bentuk yang menjadi ciri khas dari masing-masing jenis penyakit tanaman.

Berbagai penelitian sebelumnya telah menunjukkan bahwa pendekatan deep learning berbasis *Convolutional Neural Network* (CNN) mampu memberikan kinerja yang baik dalam pengenalan dan klasifikasi penyakit tanaman berdasarkan citra daun. Falaschetti et al. (2022) mengembangkan sistem klasifikasi penyakit daun tanaman berbasis CNN yang diimplementasikan pada platform OpenMV Cam H7 Plus. Penelitian tersebut menekankan efisiensi komputasi dengan biaya rendah dan konsumsi daya yang kecil, serta mampu melakukan klasifikasi penyakit tanaman secara *real-time*. Hasil penelitian menunjukkan bahwa CNN dapat diintegrasikan ke dalam perangkat keras terbatas tanpa mengorbankan akurasi [11].

Selanjutnya, Russel dan Selvaraj (2022) mengusulkan arsitektur multiscale parallel deep CNN untuk klasifikasi spesies daun dan penyakit tanaman. Model yang dikembangkan mampu mengekstraksi fitur dari berbagai skala citra secara paralel, sehingga meningkatkan kemampuan model dalam mengenali variasi pola penyakit. Penelitian ini mengombinasikan fitur *handcrafted* dan fitur yang dipelajari secara otomatis (*learnable features*), yang terbukti mampu meningkatkan akurasi klasifikasi dibandingkan arsitektur CNN konvensional [12].

Penelitian lain dilakukan oleh Rao et al. (2022) yang mengusulkan metode *deep bilinear CNN* untuk klasifikasi penyakit tanaman. Model ini mengombinasikan fitur CNN dengan pendekatan Linear Discriminant Analysis (LDA) untuk meningkatkan kemampuan pemisahan antar kelas penyakit. Hasil penelitian menunjukkan bahwa integrasi CNN dengan metode statistik klasik dapat memberikan performa klasifikasi yang lebih baik, khususnya pada dataset penyakit daun dengan karakteristik visual yang mirip [13].

Selain itu, Tejaswini et al. (2022) menerapkan CNN untuk klasifikasi penyakit daun padi, yaitu *bacterial leaf blight*, *brown spot*, dan *leaf blight*. Penelitian ini menggunakan citra daun utuh sebagai masukan tanpa segmentasi khusus, dan hasilnya menunjukkan bahwa CNN mampu mengenali pola penyakit langsung dari citra mentah. Studi ini menegaskan bahwa CNN memiliki kemampuan ekstraksi fitur yang kuat dalam domain pertanian, khususnya untuk klasifikasi penyakit tanaman berbasis citra [14].

Berdasarkan penelitian tersebut, dapat disimpulkan bahwa CNN merupakan pendekatan dalam pengenalan penyakit tanaman. Namun, sebagian penelitian masih menggunakan arsitektur CNN konvensional atau model dengan kompleksitas tinggi. Oleh karena itu, penelitian ini berfokus pada pemanfaatan arsitektur *DenseNet* berbasis sekuensial yang memiliki koneksi antar layer yang lebih efisien dalam aliran informasi dan *gradien*. Diharapkan pendekatan ini mampu meningkatkan akurasi klasifikasi serta efisiensi pembelajaran fitur pada citra daun tanaman dengan kelas *Healthy*, *Powdery*, dan *Rust*.

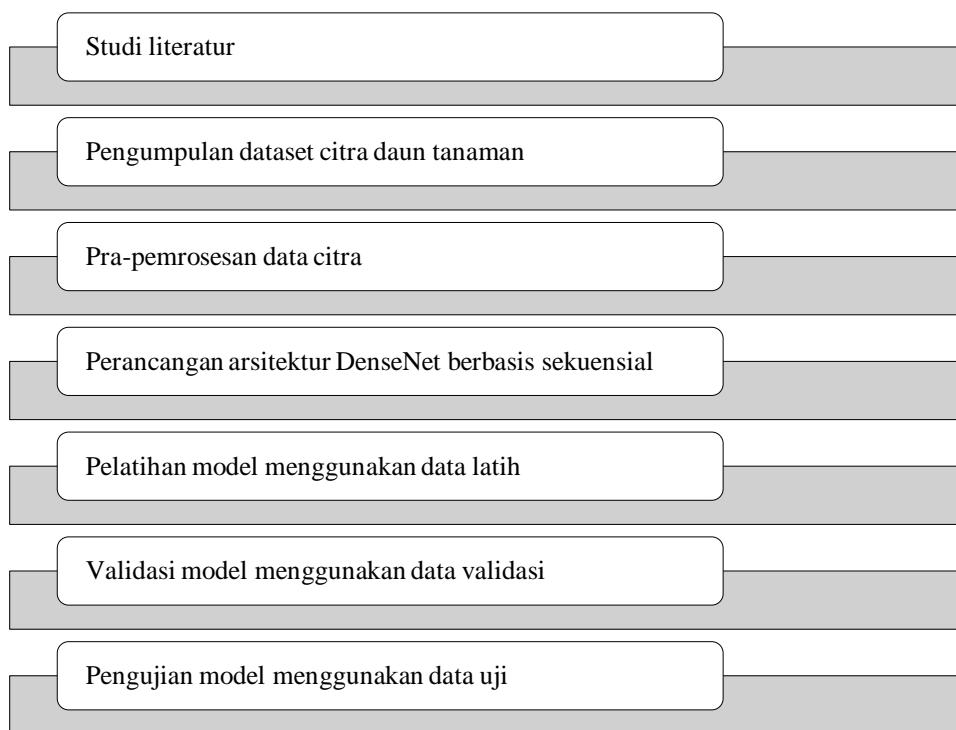
Arsitektur *Densely Connected Convolutional Network* (DenseNet) merupakan salah satu model deep learning dalam ekstraksi fitur citra. DenseNet memiliki karakteristik koneksi langsung antar layer yang memungkinkan aliran informasi dan gradien berjalan lebih optimal, sehingga dapat mengurangi masalah *vanishing gradient* dan meningkatkan efisiensi pembelajaran fitur. Selain itu, DenseNet mampu memanfaatkan kembali fitur dari layer sebelumnya, yang menjadikannya cocok untuk klasifikasi citra dengan perbedaan visual yang relatif halus seperti pada penyakit daun tanaman [15].

Dalam penelitian ini, *DenseNet* diimplementasikan menggunakan pendekatan arsitektur berbasis sekuensial, yang memungkinkan penyusunan layer secara terstruktur dan mudah dikembangkan. Pendekatan ini memudahkan proses perancangan, pelatihan, serta evaluasi model, khususnya dalam mengklasifikasikan citra daun tanaman ke dalam tiga kelas kondisi, yaitu *healthy*, *powdery*, dan *rust*. Dengan memanfaatkan dataset citra daun yang dibagi ke dalam data latih, validasi, dan uji, diharapkan model mampu memberikan kinerja klasifikasi yang akurat dan memiliki kemampuan generalisasi yang baik.

Berdasarkan uraian tersebut, penelitian ini berfokus pada penerapan arsitektur *DenseNet121* berbasis sekuensial untuk pengenalan penyakit tanaman berdasarkan citra daun. Kontribusi utama penelitian ini terletak pada pemanfaatan *DenseNet121* sebagai feature extractor dengan konfigurasi arsitektur sekuensial yang sederhana namun efektif, serta evaluasi kinerja model menggunakan dataset citra daun yang relatif seimbang pada tiga kelas, yaitu *Healthy*, *Powdery*, dan *Rust*. Hasil penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan dalam deteksi dini penyakit tanaman di bidang pertanian.

2. METODE PENELITIAN

Penelitian ini diawali dengan studi literatur untuk memahami konsep computer vision, CNN, arsitektur *DenseNet*, serta penelitian terdahulu yang relevan sebagai dasar penentuan metode. Dataset berupa citra daun tanaman dengan tiga kelas, yaitu *healthy*, *powdery*, dan *rust*, dibagi ke dalam data latih, validasi, dan uji dengan distribusi yang seimbang, kemudian digunakan untuk melatih model *DenseNet* berbasis sekuensial. Kinerja model dievaluasi menggunakan metrik accuracy, precision, recall, F1-score, serta confusion matrix untuk mengukur kemampuan klasifikasi dan generalisasi model. Adapun tahap penelitian dapat dilihat pada **Gambar 1**.



Gambar 1 Tahapan penelitian pengenalan penyakit tanaman berbasis citra daun menggunakan arsitektur *DenseNet121*.

Tahap awal penelitian diawali dengan studi literatur untuk memahami konsep dasar serta perkembangan terkini terkait pengenalan penyakit tanaman berbasis citra daun. Studi literatur ini mencakup pembahasan mengenai *computer vision*, *Convolutional Neural Network* (CNN), arsitektur *DenseNet*, serta hasil penelitian terdahulu yang relevan. Kajian ini digunakan sebagai landasan teoritis dalam menentukan metode, pendekatan, dan kerangka penelitian yang digunakan.

Tahap selanjutnya adalah pengumpulan dataset yang digunakan dalam penelitian. Dataset berupa citra daun tanaman yang terdiri dari tiga kelas kondisi, yaitu *healthy*, *powdery*, dan *rust*. Dataset ini disusun untuk merepresentasikan kondisi daun sehat dan daun yang terinfeksi penyakit, sehingga dapat digunakan sebagai data masukan dalam proses pembelajaran model.

Dataset yang telah dikumpulkan kemudian dibagi ke dalam tiga subset, yaitu data latih (*training*), data validasi (*validation*), dan data uji (*testing*). Pembagian dataset dilakukan dengan distribusi yang relatif seimbang pada setiap kelas untuk menghindari ketidakseimbangan data (*class imbalance*) yang dapat mempengaruhi kinerja model seperti pada **Tabel 1**.

Tabel 1 Distribusi Dataset Citra Penyakit Tanaman per Kelas

Kelas	Train	Validation	Test	Total
Healthy	440	20	50	510
Powdery	441	20	50	511
Rust	441	20	50	511
Total	1.322	60	150	1.530

Pada tahap ini dilakukan perancangan model klasifikasi menggunakan arsitektur DenseNet yang diimplementasikan dengan pendekatan sekuensial. Penyusunan model dilakukan secara berurutan, yang mencakup layer konvolusi, *dense block*, *pooling*, dan *fully connected layer*. Arsitektur model disesuaikan dengan jumlah kelas keluaran yang digunakan dalam penelitian.

Model yang telah dirancang kemudian dilatih menggunakan data latih dengan parameter tertentu, seperti *learning rate*, jumlah *epoch*, dan *batch size*. Selama proses pelatihan, data validasi digunakan untuk memantau performa model serta mencegah terjadinya *overfitting*. Kinerja model selama pelatihan dievaluasi berdasarkan nilai akurasi dan *loss*. Setelah proses pelatihan selesai, model diuji menggunakan data uji yang tidak pernah dilihat dalam proses pelatihan maupun validasi. Tahap pengujian ini bertujuan untuk mengukur kemampuan generalisasi model dalam mengklasifikasikan citra daun tanaman pada data baru atau kondisi nyata.

Evaluasi kinerja model dilakukan menggunakan beberapa metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*, serta confusion matrix. Hasil evaluasi ini digunakan untuk menganalisis performa model dalam mengenali masing-masing kelas penyakit tanaman serta untuk menilai efektivitas arsitektur DenseNet berbasis sekuensial yang diusulkan.

3. HASIL DAN ANALISIS

Model yang digunakan dalam penelitian ini dibangun dengan memanfaatkan arsitektur *DenseNet121*. *DenseNet121* dipilih karena memiliki koneksi antar layer yang padat (*densely connected*), sehingga mampu meningkatkan aliran informasi dan *gradien* selama proses pelatihan. Model ini menggunakan bobot awal (*pre-trained weights*) dari *ImageNet* untuk memanfaatkan pengetahuan awal dari dataset skala besar.

Pada tahap awal, *DenseNet121* digunakan sebagai base model dengan parameter *include_top=False*, sehingga lapisan klasifikasi bawaan *DenseNet* dihilangkan. Pendekatan ini memungkinkan penyesuaian arsitektur model dengan kebutuhan klasifikasi penyakit tanaman yang terdiri dari tiga kelas. Ukuran citra masukan ditetapkan sebesar $224 \times 224 \times 3$ agar sesuai dengan spesifikasi arsitektur *DenseNet121*. Seluruh layer pada base model *DenseNet121* dibuat tidak dapat dilatih (*non-trainable*). Strategi ini bertujuan untuk mempertahankan bobot hasil pelatihan sebelumnya dan mengurangi risiko *overfitting*, terutama ketika jumlah dataset yang digunakan relatif terbatas. Dengan demikian, *DenseNet* berperan sebagai *feature extractor* dalam mengekstraksi ciri penting dari citra daun tanaman.

Model selanjutnya dibangun menggunakan pendekatan sekuensial dengan menambahkan *DenseNet121* sebagai lapisan awal. Setelah itu, diterapkan *GlobalAveragePooling2D* untuk mereduksi dimensi fitur spasial menjadi vektor satu dimensi, sehingga jumlah parameter dapat dikurangi tanpa menghilangkan informasi fitur. Pada bagian klasifikasi, ditambahkan sebuah *layer Dense* dengan 128 *neuron* dan fungsi aktivasi *ReLU* untuk meningkatkan kemampuan model dalam mempelajari pola nonlinier. Selanjutnya, digunakan *Dropout* sebesar 0,3 untuk mengurangi risiko *overfitting*. Lapisan keluaran menggunakan *Dense* dengan 3 *neuron* dan fungsi aktivasi Softmax untuk menghasilkan probabilitas masing-masing kelas.

Berdasarkan ringkasan model, total parameter yang digunakan adalah 7.169.091, dengan 131.587 parameter yang dapat dilatih dan 7.037.504 parameter yang tidak dapat dilatih. Model kemudian dikompilasi menggunakan optimizer Adam dan fungsi loss *categorical crossentropy* yang sesuai untuk klasifikasi multikelas berbasis citra. Berdasarkan hasil pelatihan model *DenseNet*, diperoleh nilai akurasi data latih (*training*) sebesar 98,28% dan akurasi data validasi (*validation*) sebesar 96,25%. Nilai akurasi training yang tinggi menunjukkan bahwa model mampu mempelajari pola dan karakteristik citra daun tanaman dengan sangat baik. Sementara itu, akurasi validasi yang juga tinggi serta memiliki selisih yang relatif kecil dibandingkan akurasi training mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting*.

Pada klasifikasi penyakit tanaman berdasarkan data pengujian, confusion matrix menampilkan perbandingan antara kelas aktual dan kelas hasil prediksi untuk setiap kondisi daun, seperti Healthy, Powdery, dan Rust. Melalui matriks ini, dapat diketahui jumlah prediksi yang benar maupun kesalahan klasifikasi yang terjadi pada masing-masing kelas, sehingga memberikan gambaran yang lebih rinci dibandingkan hanya melihat nilai akurasi secara keseluruhan. Hasil *confusion matrix* berdasarkan data pengujian dapat diihat pada **Gambar 2**.

Kelas Aktual \ Prediksi	Healthy	Powdery	Rust
Healthy	46	1	3
Powdery	3	46	1
Rust	1	1	48

Gambar 2 *Confusion matrix* hasil klasifikasi penyakit tanaman berdasarkan data uji pada kelas *Healthy*, *Powdery*, dan *Rust*.

Berdasarkan *confusion matrix* klasifikasi penyakit tanaman, terlihat bahwa model mampu mengklasifikasikan sebagian besar citra daun tanaman dengan baik pada setiap kelas. Pada kelas *Healthy*, sebanyak 46 citra berhasil diklasifikasikan dengan benar, sementara 4 citra mengalami kesalahan prediksi menjadi kelas *Powdery* dan *Rust*. Untuk kelas *Powdery*, model juga menunjukkan kinerja yang baik dengan 46 citra terkласifikasi benar, meskipun masih terdapat kesalahan prediksi masing-masing sebanyak 3 citra sebagai *Healthy* dan 1 citra sebagai *Rust*. Pada kelas *Rust*, performa model paling tinggi ditunjukkan dengan 48 citra terklasifikasi benar dan hanya 2 citra yang salah diklasifikasikan. *Confusion matrix* ini menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik dengan tingkat kesalahan yang relatif rendah dan distribusi kesalahan yang masih dapat ditoleransi antar kelas. Terlihat juga bahwa kesalahan klasifikasi masih terjadi terutama antara kelas *Healthy* dan *Powdery*. Hal ini diduga disebabkan oleh kemiripan karakteristik visual pada tahap awal infeksi, di mana perubahan warna dan tekstur daun belum terlihat secara signifikan. Selain itu, variasi pencahayaan dan sudut pengambilan citra juga dapat mempengaruhi distribusi intensitas warna pada citra daun, sehingga menyulitkan model dalam membedakan kelas yang memiliki perbedaan visual yang relatif halus.

Perhitungan *precision*, *recall*, dan *F1-score* pada setiap kelas sangat penting untuk mengevaluasi kinerja model klasifikasi secara lebih mendalam, terutama pada pengenalan penyakit tanaman. *Precision* menunjukkan tingkat ketepatan model dalam memprediksi suatu kelas, yaitu seberapa banyak prediksi yang dihasilkan benar, sedangkan *recall* menggambarkan kemampuan model dalam mengenali seluruh data yang benar-benar termasuk ke dalam kelas tersebut. *F1-score* berfungsi sebagai ukuran keseimbangan antara *precision* dan *recall*, sehingga memberikan gambaran kinerja model yang lebih adil ketika terjadi ketidakseimbangan kesalahan prediksi. Perhitungan *precision*, *recall*, dan *F1-score* dapat dilihat pada **Tabel 2**.

Tabel 2 Hasil Evaluasi Klasifikasi Berdasarkan *Confusion Matrix*

Kelas	Precision	Recall	F1-Score
<i>Healthy</i>	0.92	0.92	0.92
<i>Powdery</i>	0.96	0.92	0.94
<i>Rust</i>	0.92	0.96	0.94
<i>Accuracy</i>	—	—	0.93
<i>Macro Avg</i>	0.93	0.93	0.93
<i>Weighted Avg</i>	0.93	0.93	0.93

Berdasarkan hasil evaluasi klasifikasi berdasarkan *confusion matrix*, dapat dilihat bahwa model menunjukkan kinerja yang baik dalam mengklasifikasikan penyakit tanaman pada ketiga kelas yang diuji. Nilai *precision*, *recall*, dan *F1-score* pada kelas *Healthy* masing-masing sebesar 0,92, yang menunjukkan bahwa model memiliki ketepatan dan kemampuan pengenalan yang seimbang dalam mengidentifikasi daun sehat. Hal ini menandakan bahwa sebagian besar citra daun sehat dapat diklasifikasikan dengan benar oleh model.

Pada kelas *powdery* dan *rust*, model juga menunjukkan performa yang tinggi dengan nilai *F1-score* masing-masing sebesar 0,94. Kelas *powdery* memiliki nilai *precision* yang lebih tinggi (0,96) dibandingkan *recall* (0,92), yang menunjukkan bahwa prediksi kelas *powdery* cenderung lebih tepat meskipun masih terdapat beberapa data yang tidak terdeteksi. Sebaliknya, kelas *rust* memiliki nilai *recall* yang lebih tinggi (0,96) dibandingkan *precision* (0,92), yang mengindikasikan bahwa model sangat baik dalam mengenali hampir seluruh data *rust*, meskipun masih terdapat sedikit kesalahan prediksi ke kelas lain.

Nilai *macro average* dan *weighted average* yang sama-sama sebesar 0,93 menandakan bahwa kinerja model relatif konsisten pada setiap kelas dan tidak dipengaruhi oleh perbedaan jumlah data antar kelas. Hasil ini menunjukkan bahwa model *DenseNet* berbasis sekuensial memiliki kemampuan klasifikasi yang stabil dalam mengenali penyakit tanaman berdasarkan citra daun. Model menghasilkan nilai *accuracy* sebesar 0,93, yang

menunjukkan bahwa 93% data uji berhasil diklasifikasikan dengan benar dengan perhitungan sesuai dengan **Persamaan (1)**.

$$Accuracy = \frac{\text{Jumlah prediksi benar}}{\text{Jumlah seluruh data}} \quad (1)$$

$$Accuracy = \frac{140}{150} = 0,9333$$

Perhitungan akurasi dilakukan dengan membandingkan jumlah prediksi yang benar terhadap jumlah seluruh data uji yang digunakan. Berdasarkan hasil klasifikasi, dari total 150 data uji, model berhasil mengklasifikasikan 140 data dengan benar, sehingga nilai akurasi diperoleh dari perbandingan 140/150, yaitu sebesar 0,93 atau 93,33%.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model pengenalan penyakit tanaman berbasis citra daun menggunakan arsitektur *DenseNet121* berbasis sekuensial mampu memberikan kinerja klasifikasi yang baik. Model berhasil mengklasifikasikan tiga kelas kondisi daun, yaitu *Healthy*, *Powdery*, dan *Rust*, dengan akurasi sebesar 98,28% pada data latih, 96,25% pada data validasi, dan 93,33% pada data uji. Hasil ini menunjukkan bahwa pemanfaatan *DenseNet121* sebagai *feature extractor* dengan bobot *pre-trained ImageNet* dalam mengekstraksi ciri penting dari citra daun tanaman. Evaluasi menggunakan *confusion matrix* serta metrik *precision*, *recall*, dan *F1-score* menunjukkan bahwa model memiliki performa yang konsisten pada setiap kelas dengan tingkat kesalahan klasifikasi yang relatif rendah. Hal ini menandakan bahwa arsitektur *DenseNet* berbasis sekuensial memiliki kemampuan generalisasi yang baik dan dapat digunakan sebagai pendekatan yang andal dalam pengenalan penyakit tanaman berdasarkan citra daun. Untuk pengembangan penelitian selanjutnya, disarankan untuk melakukan *fine-tuning* pada beberapa layer *DenseNet* agar model dapat mempelajari fitur yang lebih spesifik terhadap karakteristik penyakit tanaman. Selain itu, penelitian selanjutnya dapat menggunakan dataset yang lebih besar dan lebih beragam, baik dari segi jenis tanaman maupun variasi kondisi lingkungan, guna meningkatkan kemampuan generalisasi model.

UCAPAN TERIMA KASIH

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

REFERENSI

- [1] R. Asra, F. Andriani, M. Silalahi, I. A. Fijridiyanto, and A. T. Maryani, "Diversity of medicinal plants sold in the traditional markets in Jambi, Indonesia," *Biodiversitas*, vol. 24, no. 3, 2023, doi: 10.13057/biodiv/d240326.
- [2] M. A. Rahman, M. S. N. Shoumik, M. M. Rahman, and M. H. Hena, "Rice Disease Detection Based on Image Processing Technique," pp. 135–145, 2021, doi: 10.1007/978-981-15-5224-3_13.
- [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. Nusant.*, 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/ijicic.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] L. Falaschetti, L. Manoni, D. Di Leo, D. Pau, V. Tomaselli, and C. Turchetti, "A CNN-based image detector for plant leaf diseases classification," *HardwareX*, vol. 12, p. e00363, 2022.
- [12] N. S. Russel and A. Selvaraj, "Leaf species and disease classification using multiscale parallel deep CNN architecture," *Neural Comput. Appl.*, vol. 34, no. 21, pp. 19217–19237, 2022.

- [13] D. S. Rao *et al.*, “Plant disease classification using deep bilinear CNN,” *Intell. Autom. Soft Comput.*, vol. 31, no. 1, pp. 161–176, 2022.
- [14] P. Tejaswini, P. Singh, M. Ramchandani, Y. K. Rathore, and R. R. Janghel, “Rice leaf disease classification using CNN,” in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, 2022, p. 12017.
- [15] S. Nandhini and K. Ashokkumar, “An automatic plant leaf disease identification using DenseNet-121 architecture with a mutation-based henry gas solubility optimization algorithm,” *Neural Comput. Appl.*, vol. 34, no. 7, pp. 5513–5534, 2022.