



PERBANDINGAN METODE TRANSFER LEARNING DALAM KLASIFIKASI PENYAKIT DAUN PADI

Aldi Daffa Arisyi¹⁾, Muhammad Aidil Saputra²⁾, Muhammad Rafif Hanif³⁾, Anindita Septiarini⁴⁾, Akhmad Irsyad⁵⁾

^{1,2,3,4,5} Program Studi Informatika, Universitas Mulawarman

email: ¹aldidaffaarisyi@gmail.com, ²aidil3669@gmail.com, ³rafiffullbuster@gmail.com, ⁴anindita@unmul.ac.id, ⁵akhmadirsyad@unmul.ac.id

ARTICLE INFO	ABSTRACT
<p>Article History: Recieved : 23 Januari 2026 Accepted : 12 April 2026 Published : 02 Juni 2026</p>	<p><i>This study compares four transfer learning-based CNN models, namely VGG19, ResNet152, MobileNetV2, and DenseNet121, for the classification of 10 classes of rice leaf diseases. Evaluation results on the test dataset show that ResNet152 achieves the best performance with an accuracy of 0.9553, precision of 0.9589, recall of 0.9553, and F1-score of 0.9558, followed by DenseNet121 (accuracy 0.9433), MobileNetV2 (0.9353), and VGG19 (0.9247). ResNet152 excels in recognizing complex features through its skip connection mechanism, while DenseNet121 is more efficient with the lowest validation loss. MobileNetV2 is the lightest and fastest model, making it suitable for resource-limited devices. Based on the confusion matrix analysis, all models are able to classify the neck blast class perfectly; however, misclassifications still occur among visually similar classes such as brown spot, narrow brown spot, and leaf blast. Overall, transfer learning is proven effective for rice leaf disease classification, with ResNet152 and DenseNet121 being the most recommended models.</i></p>
<p>Keywords: Rice leaf disease Transfer learning ResNet152 DenseNet121 Image Classification</p>	
<p>IEEE style in citing this article: A. D. Arisyi, M. A. Saputra, M. R. Hanif, A. Setiarini, A. Irsyad, "Perbandingan Metode Transfer Learning Dalam Klasifikasi Penyakit Daun Padi", <i>jurnal.ilmiah.informatika</i>, vol. 11, no. 1, pp. 24-xx, Juni. 2026.</p>	

© 2026 Jurnal Ilmiah Informatika (Scientific Informatics Journal) with CC BY NC licence

1. PENDAHULUAN

Padi (*Oryza sativa* L.) merupakan tanaman pangan paling strategis di

Indonesia. Sebagaimana dikemukakan Istiqomah & Murinto [1], hampir 95% penduduk Indonesia menjadikan beras

sebagai makanan pokok, sehingga pada setiap tahunnya permintaan akan kebutuhan beras semakin meningkat seiring dengan bertambahnya jumlah penduduk. Tingginya ketergantungan pada komoditas ini menjadikan stabilitas produksi padi sebagai isu kritis dalam ketahanan pangan nasional. Produktivitas padi kerap terganggu oleh serangan penyakit pada bagian daun, antara lain *bacterial leaf blight*, *brown spot*, *leaf blast*, *neck blast*, *leaf scald*, *narrow brown spot*, *rice hispa*, *sheath blight*, dan *tungro*. Menurut Al Rajab & Nafiiyah [2], penyakit-penyakit daun padi tersebut berdampak langsung pada ketahanan pangan nasional dan menjadi penyebab utama penurunan produktivitas pertanian. Sebagaimana dibuktikan oleh Maulana et al. [3], jika penyakit tidak cepat dikenali dan ditangani, hal ini bisa menyebabkan hasil panen menurun drastis dan mengganggu pasokan beras di dalam negeri.

Selama ini, identifikasi penyakit tanaman padi masih mengandalkan pengamatan visual secara manual oleh petani maupun petugas pertanian lapangan. Sebagaimana diungkapkan Al Rajab & Nafiiyah [2], metode ini tidak objektif dan sangat bergantung pada pengalaman seseorang, dan kondisi tersebut semakin kompleks karena kurangnya tenaga ahli patologi tanaman dan penyebaran penyuluh yang tidak merata. Selain itu, minimnya pengetahuan dan wawasan petani dalam mengidentifikasi dan mendiagnosa jenis penyakit padi menjadi penyebab kurangnya hasil produksi padi [2], [4] Hawari et al. [5] menyatakan bahwa penelitian klasifikasi penyakit padi berbasis CNN bertujuan untuk membantu

dan mengedukasi petani dalam mengklasifikasi penyakit serta mengurangi risiko kegagalan panen, yang mengindikasikan pentingnya sistem deteksi otomatis berbasis AI.

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *deep learning* yang terbukti efektif untuk tugas klasifikasi citra. Keunggulan CNN terletak pada kemampuannya yang tidak memerlukan ekstraksi fitur karena fitur ekstraksi sudah terintegrasi secara otomatis dalam CNN [5]. Kemampuan inilah yang menjadikan CNN, khususnya melalui pendekatan *transfer learning*, sebagai pilihan utama dalam berbagai penelitian deteksi penyakit tanaman berbasis citra daun.

Berbagai penelitian telah mengeksplorasi penerapan CNN untuk klasifikasi penyakit daun padi. Khoiruddin et al. [6] menggunakan CNN pada dataset citra penyakit daun padi dan melaporkan akurasi terbaik sebesar 98% pada epoch ke-100. Istiqomah & Murinto [1] membandingkan CNN dasar dengan VGG16 menggunakan empat kelas penyakit padi; hasil penelitian menunjukkan bahwa CNN menghasilkan akurasi sebesar 88 dan untuk VGG16 memperoleh nilai akurasi sebesar 93, sehingga VGG16 memperoleh akurasi yang lebih tinggi jika dibandingkan dengan CNN dalam mengklasifikasikan jenis penyakit tanaman padi berbasis citra daun. Shinta et al. [7] menerapkan arsitektur VGG-19 dengan dan tanpa augmentasi data pada empat kelas penyakit daun padi; hasil pengujian menunjukkan bahwa akurasi tertinggi menggunakan augmentasi data yang diperoleh sebesar 94,31%, sedangkan

akurasi tertinggi tanpa augmentasi data yang diperoleh sebesar 93,18%, sehingga augmentasi dapat meningkatkan hasil akurasi. Maulana et al. [3] mengembangkan sistem identifikasi penyakit daun padi otomatis memanfaatkan citra digital dan arsitektur ResNet50V2 untuk mengenali delapan jenis penyakit; berdasarkan hasil pengujian, model menunjukkan akurasi tertinggi sebesar 94,14% pada data uji. Agustina et al. [3] mengklasifikasikan penyakit tanaman padi menggunakan arsitektur DenseNet-121 dengan augmentasi data; hasil terbaik dari beberapa pengujian diperoleh akurasi terbaik sebesar 99,17% dan *loss* 0,0355 menggunakan model DenseNet-121. Sementara itu, Al Rajab & Nafiiyah [2] mengevaluasi dan membandingkan kinerja sembilan arsitektur CNN berbasis *transfer learning* dalam klasifikasi penyakit daun padi; hasil penelitian menunjukkan bahwa MobileNetV3Large, VGG16, dan ResNet101 memiliki akurasi tertinggi sebesar 100,00%, 99,58%, dan 99,17%, masing-masing.

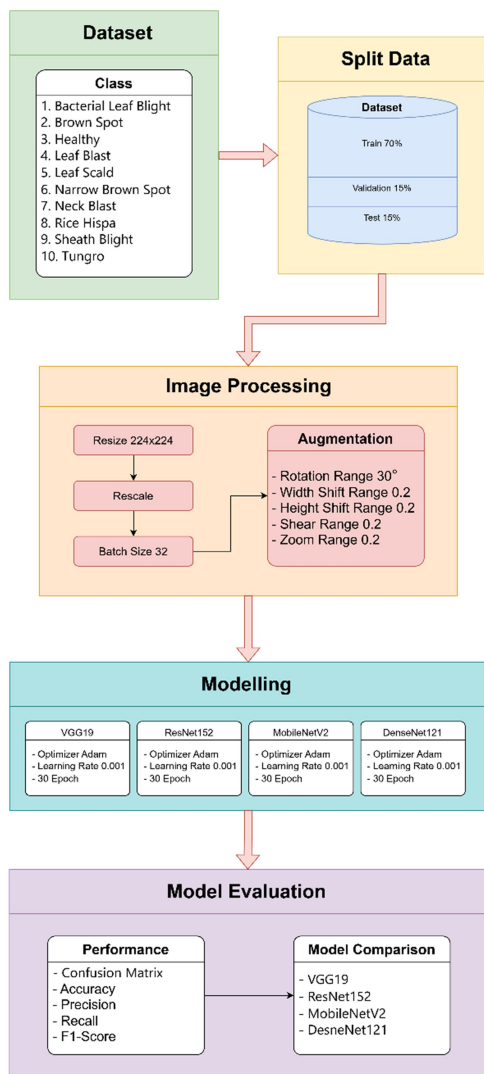
Meskipun penelitian-penelitian tersebut menunjukkan hasil yang menjanjikan, sejumlah kesenjangan (*research gap*) masih perlu diperhatikan. Pertama, sebagian besar penelitian hanya menguji satu arsitektur CNN tunggal sehingga tidak memberikan gambaran perbandingan kinerja yang objektif antar-model dalam kondisi eksperimen yang seragam [4], [6]. Kedua, perbedaan jumlah kelas penyakit, ukuran dataset, dan teknik augmentasi yang digunakan di berbagai penelitian menyulitkan perbandingan langsung antar-studi [1], [7], [8]. Ketiga, beberapa penelitian yang mencapai nilai

akurasi sangat tinggi belum menyertakan analisis mendalam mengenai potensi *overfitting* dan kemampuan generalisasi model terhadap data di luar kondisi laboratorium [2]. Keempat, penelitian yang mengkombinasikan performa klasifikasi tinggi dengan efisiensi komputasi yang memungkinkan implementasi pada perangkat bergerak milik petani masih sangat terbatas, padahal aspek ini krusial untuk penerapan di lapangan secara nyata.

Berdasarkan analisis kesenjangan tersebut, penelitian ini bertujuan untuk: (1) membangun dan melatih empat model CNN berbasis *transfer learning*, yaitu VGG19, ResNet152, MobileNetV2, dan DenseNet121, untuk klasifikasi 10 kelas penyakit daun padi menggunakan dataset publik dari Kaggle; (2) mengevaluasi dan membandingkan kinerja keempat model secara komprehensif dalam kondisi yang seragam menggunakan metrik akurasi, *precision*, *recall*, dan *F1-Score*; serta (3) mengidentifikasi arsitektur CNN yang paling optimal ditinjau dari keseimbangan antara akurasi klasifikasi dan efisiensi komputasi guna mendukung pengembangan sistem deteksi dini penyakit padi yang praktis dan dapat diimplementasikan di lapangan.

2. METODE PENELITIAN

Berdasarkan Gambar 1, penelitian ini dimulai dari tahapan pengumpulan dataset, lalu pembagian data, selanjutnya pemrosesan citra, metode yang digunakan adalah VGG19, ResNet152, MobileNetV2, dan DenseNet121, serta dilanjutkan dengan evaluasi dan analisis perbandingan model.



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Penelitian ini menggunakan dataset publik berisi citra penyakit daun padi dengan nama "Rice Leaf Diseases Detection" bersumber dari website Kaggle (<https://www.kaggle.com/datasets/loki4514/rice-leaf-diseases-detection>). Dataset ini memiliki jumlah total citra sebanyak 18.445 citra yang sudah dibagi menjadi data latih dan data uji dan memiliki 10 kelas di dalamnya seperti pada Tabel 1.

Tabel 1. Dataset Website Kaggle

Kelas	Latih	Uji
Bacterial Leaf Blight	1386	376
Brown Spot	1491	380
Healthy	1492	391
Leaf Blast	1801	362
Leaf Scald	1670	386
Narrow Brown Spot	1416	382
Neck Blast	1000	322
Rice Hispa	1461	225
Sheath Blight	1578	288
Tungro	1740	310


2.2 Pembagian Data

Sebelum melakukan pembagian data, perlu dilakukan pembersihan data karena jumlah data setiap kelasnya tidak seimbang. Setelah Pembersihan diperoleh jumlah data sebanyak 1000 citra untuk setiap kelas. Selanjutnya, pembagian data menggunakan rasio data latih 75%, data validasi 15%, dan data uji 15% yang hasil pembersihan dan pembagian data disajikan dalam Tabel 2.

Tabel 2. Dataset Setelah Pembersihan dan Pembagian Data


Kelas	Latih	Validasi	Uji
Bacterial Leaf Blight	750	150	150
Brown Spot	750	150	150
Healthy	750	150	150
Leaf Blast	750	150	150
Leaf Scald	750	150	150
Narrow Brown Spot	750	150	150

model lebih sedikit [15]. *Depthwise convolution* melakukan setiap pada setiap channel input secara terpisah, sementara *pointwise convolution* menggabungkan output dari *depthwise convolution* [16], [17]



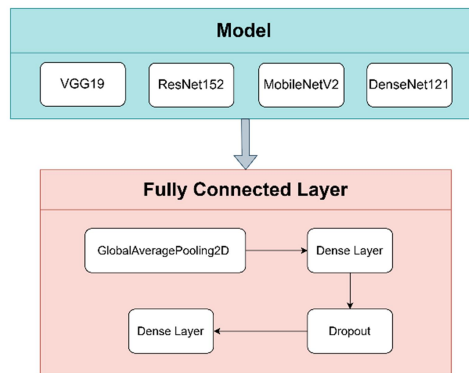
Gambar 4. Tahap Depthwise dan Pointwise Convolution

Seperti Gambar 5, DenseNet121 merupakan arsitektur yang menerapkan konektivitas padat di setiap lapisan yang terhubung secara langsung dari semua lapisan sebelumnya, memungkinkan fitur yang sudah dipelajari sebelumnya digunakan berulang kali sehingga mengurangi jumlah parameter serta proses pelatihan lebih cepat [18], [19].



Gambar 5. Arsitektur DenseNet121

Model di modifikasi dengan menambahkan beberapa lapisan tambahan pada bagian *fully connected* agar dapat mengklasifikasikan penyakit daun padi. Modifikasi diterapkan pada semua model seperti pada Gambar 6, agar perbandingan performa setiap model dapat diukur secara adil dan objektif.



Gambar 6. Modifikasi yang diterapkan

Gambar 6 menampilkan modifikasi yang diterapkan pada lapisan *fully connected*. *GlobalAveragePooling2D* digunakan untuk mengurangi dimensi citra vektor satu dimensi dengan menghitung setiap fitur konvolusi untuk mengurangi jumlah parameter [20]. *Dense* dengan 512 neuron aktivasi ReLu untuk mempelajari pola visual yang telah diekstraksi [21]. *Dropout* 0.5 mematikan 50% neuron secara acak selama pelatihan untuk mencegah *overfitting* [22]. Terakhir, lapisan *Dense* dengan 10 neuron dan aktivasi *softmax* untuk menghasilkan probabilitas klasifikasi 10 kelas penyakit daun padi.

Keempat model dilatih selama 30 *epoch* dengan batch size 32 yang memproses 32 citra dalam satu iterasi [23]. *Optimizer* Adam digunakan karena menggabungkan momentum dan RMSProp untuk mengatasi gradien renggang secara optimal [24]. Digunakan *learning rate* 0.001 untuk menjaga stabilitas bobot dan mencegah konvergensi berjalan terlalu lambat [25].

2.5 Evaluasi Model

Evaluasi model dilakukan menggunakan *confusion matrix* untuk membandingkan hasil prediksi model dengan data aktual [26]. Kemudian dari *confusion matrix* dapat dihitung *accuracy*, *precision*, *recall*, dan *F1-Score* pada Persamaan (2), (3), (4), dan (5) [27].

$$Accuracy = \frac{TP}{TP + FP} \quad (2)$$

$$Precision = \frac{TP}{TP + FN} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F1 - Score = 2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (5)$$

Keterangan:

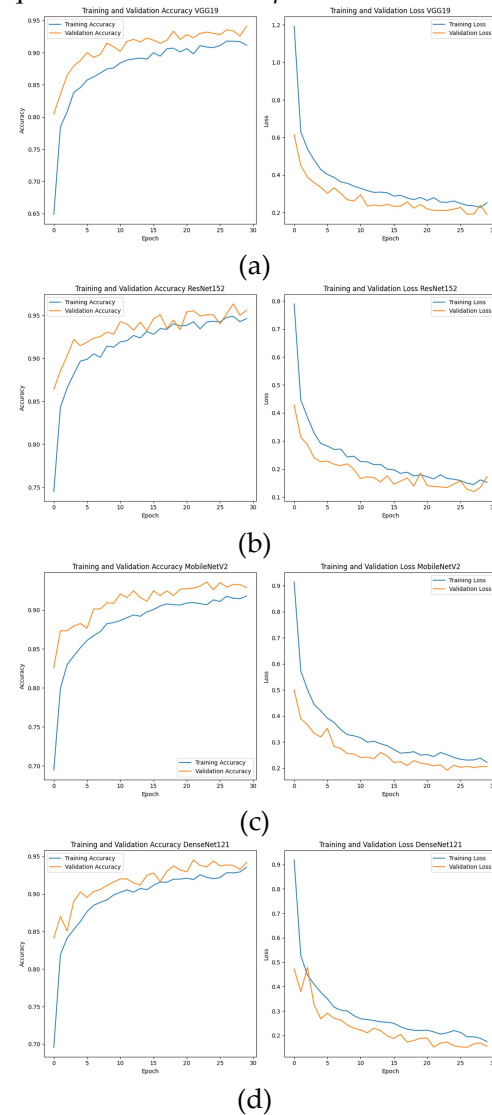
- TP (True Positive), jumlah prediksi benar yang termasuk dalam kelas tersebut.
- TN (True Negative), jumlah prediksi benar yang yang tidak termasuk kelas tersebut.
- FP (False Positive), jumlah prediksi salah yang termasuk dalam kelas tersebut.
- FN (False Negative), jumlah prediksi salah yang yang tidak termasuk kelas tersebut.

Accuracy mengukur total prediksi yang benar dari keseluruhan data uji yang diprediksi [28]. *Precision* mengukur ketepatan prediksi model pada kelas tertentu [29]. *Recall* mengukur sensitivitas model dalam mengenali seluruh data positif aktual [30]. *F1-Score* merupakan rata-rata harmonik antara *precision* dan *recall*, keduanya digunakan untuk mengevaluasi performa model pada data yang tidak seimbang [31]

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

Hasil *accuracy* dan *loss* selama proses pelatihan model VGG19, ResNet152, MobileNetV2, dan DenseNet121 divisualisasikan melalui grafik pada Gambar 7. Setiap grafik data pelatihan dan data validasi untuk mengetahui performa model setelah pelatihan selama 30 *epoch*.



Gambar 7. Hasil Pelatihan (a) VGG19, (b) ResNet152, (c) MobileNetV2, (d) DenseNet121

Berdasarkan visualisasi tersebut, ResNet152 (b) menunjukkan *accuracy* validasi tertinggi sebesar 0.9560 dan *loss* 0.1730, serta waktu pelatihan 2 detik/langkah. Sementara itu,

DenseNet121 (d) memperoleh *loss* validasi terendah sebesar 0.1555 dan *accuracy* 0.9420, serta waktu pelatihan 1 detik/langkah. MobileNetV2 menjadi model yang paling ringan dengan waktu pelatihan kurang dari 1 detik/langkah, memperoleh *accuracy* validasi sebesar 0.9287 dan *loss* 0.2067. Sedangkan VGG19 (a) menjadi model yang paling berat dengan waktu pelatihan 3 detik/langkah, namun tetap memperoleh *accuracy* validasi yang lebih tinggi dari MobileNetV2 sebesar 0.9413 dengan *loss* 0.1896.

3.2 Performa Model Pada Data Uji

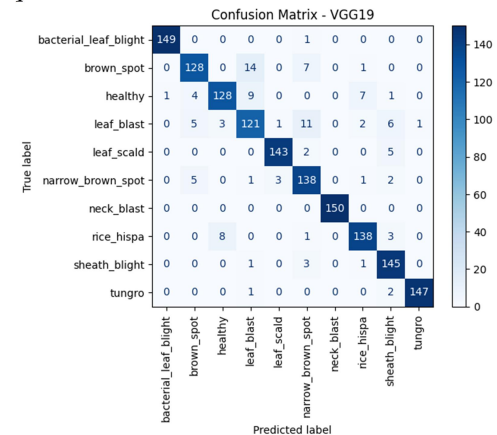
Tabel 3 menampilkan *accuracy*, *precision*, *recall*, dan *F1-Score* dari masing-masing model yang dievaluasi pada data uji. Berdasarkan hasil evaluasi tersebut, model ResNet152 menunjukkan performa yang paling tinggi secara keseluruhan dengan hasil *accuracy* sebesar 0.9553, *precision* 0.9589, *recall* 0.9553, dan *F1-Score* 0.9558. Posisi kedua ditempati oleh model DenseNet121 dengan *accuracy* 0.9433. Selanjutnya MobileNetV2 dengan nilai *accuracy* 0.9353. Sementara itu, VGG19 memperoleh nilai *accuracy* terendah sebesar 0.9247.

Tabel 3. Perbandingan Accuracy, Precision, Recall, dan F1-Score


Model	Acc	Pre	Rec	F1
VGG19	0.9247	0.9256	0.9247	0.9246
ResNet152	0.9553	0.9589	0.9553	0.9558
MobileNetV2	0.9353	0.9376	0.9353	0.9355
DenseNet121	0.9433	0.9459	0.9433	0.9439

Selain hasil performa yang ditampilkan pada Tabel 3, detail analisis terkait hasil klasifikasi yang benar atau salah divisualisasikan pada

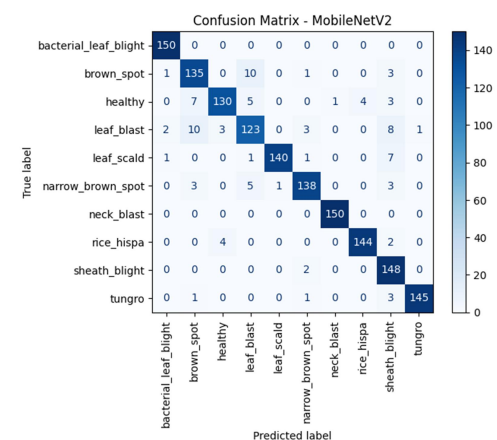
confusion matrix yang ditampilkan pada Gambar 8.



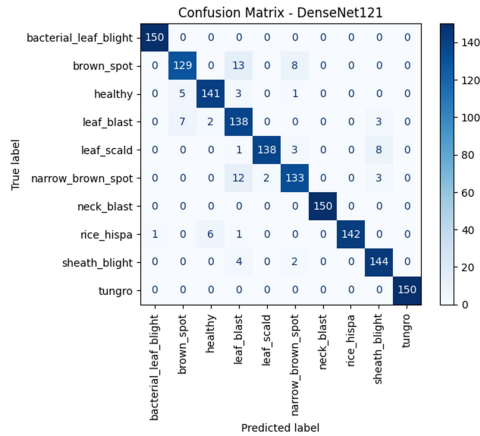
(a)



(b)



(c)



(d)

Gambar 8. Confusion Matrix, (a) VGG19, (b) ResNet152, (c) MobileNetV2, (d) DenseNet121

Berdasarkan visualisasi confusion matrix, keempat model menunjukkan ketepatan yang tinggi dalam mengklasifikasikan 10 penyakit daun padi. Kelas *neck blast* merupakan kelas yang paling mudah diklasifikasikan secara sempurna oleh keempat model. Sementara itu, kelas dengan karakteristik visual yang mirip seperti *brown spot*, *leaf blast*, dan *narrow brown spot* merupakan kelas dengan kesalahan klasifikasi terbanyak.

ResNet152 (b) menunjukkan performa yang paling unggul dibanding dengan ketiga model lainnya. Keunggulan ini diperoleh karena penggunaan mekanisme *skip connection* pada lapisan yang sangat dalam hingga 152 lapisan. Mekanisme ini efektif dalam mengatasi masalah *vanishing gradient* selama pelatihan, sehingga ResNet152 dapat mengekstraksi fitur visual yang kompleks tanpa mengalami penurunan performa.

Walaupun demikian, penelitian ini masih memiliki keterbatasan terutama pada dataset citra penyakit daun padi yang digunakan. Dataset dalam penelitian ini bersumber dari dataset

publik yang lebih diatur bagaimana proses pengambilan citranya. Di mana citra diambil dalam sudut pengambilan di tingkat pencahayaan yang seragam. Jika model dihadapkan dengan citra baru dengan variasi sudut atau pencahayaan yang berbeda, memungkinkan model menjadi ragu hingga melakukan kesalahan klasifikasi. Berdasarkan keterbatasan tersebut, disarankan pada penelitian berikutnya untuk menggunakan dataset yang citranya lebih bervariasi dalam pengambilan citranya.

ResNet152 terbukti memperoleh *accuracy* tertinggi sebesar 0.9553 walaupun dengan waktu pelatihan yang cukup lama yaitu 2 detik/langkah. Hal ini menjadikan model tersebut berat jika diterapkan pada perangkat dengan spesifikasi yang rendah. Oleh karena itu disarankan untuk menggunakan arsitektur CNN lainnya yang lebih ringan jika diterapkan pada perangkat pada spesifikasi yang rendah maupun untuk memperoleh performa yang lebih tinggi.

4. KESIMPULAN

Penelitian ini membandingkan VGG19, ResNet152, MobileNetV2, dan DenseNet121 untuk klasifikasi 10 penyakit daun padi. Hasil uji menunjukkan ResNet152 sebagai model terbaik dengan *accuracy* 0.9560, diikuti DenseNet121 (0.9433), MobileNetV2 (0.9353), dan VGG19 (0.9247). ResNet152 unggul dalam mengenali fitur kompleks, DenseNet121 lebih efisien, sedangkan MobileNetV2 paling ringan dan cepat. Semua model mengklasifikasikan *neck blast* dengan sempurna, namun masih terjadi kesalahan pada kelas yang mirip secara visual seperti *brown spot* dan *leaf blast*.

5. REFERENSI

- [1] N. Istiqomah and M. Murinto, "Klasifikasi Penyakit Tanaman Padi Berbasis Citra Daun Menggunakan Convolutional Neural Network (CNN)," *JSTIE (Jurnal Sarjana Teknik Informatika) (E-Journal)*, vol. 12, no. 1, p. 18, Feb. 2024, doi: 10.12928/jstie.v12i1.27314.
- [2] T. Y. Al Rajab and N. Nafiiyah, "Evaluasi Kinerja Model CNN Berbasis Transfer Learning dalam Klasifikasi Penyakit Daun Padi," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 7, no. 3, pp. 989–995, Mar. 2026, doi: 10.30865/json.v7i3.9539.
- [3] M. F. A. Maulana, N. M. Anggadimas, and D. A. Sani, "Klasifikasi Citra Penyakit Daun Padi Dengan Metode CNN Menggunakan Arsitektur ResNet50V2," *Journal of Computer Engineering, System and Science*, vol. 10, no. 2, pp. 517–529, Jul. 2025, doi: <https://doi.org/10.24114/cess.v10i2.66960>.
- [4] A. Agustina, F. Yanto, E. Budianita, I. Iskandar, and F. Syafria, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode CNN Arsitektur DenseNet-121 dan Augmentasi Data," *JOISIE (Journal Of Information Systems And Informatics Engineering)*, vol. 8, no. 1, pp. 124–134, 2024, doi: 10.35145/joisie.v8i1.4256.
- [5] F. H. Hawari, F. Fadillah, M. R. Alviandi, and T. Arifin, "Klasifikasi Penyakit Padi Menggunakan Algoritma CNN (Convolutional Neural Network)," *Jurnal Responsif*, vol. 4, no. 2, pp. 184–189, 2022, doi: <https://doi.org/10.51977/jti.v4i2.856>.
- [6] R. Ardianto and S. K. Wibisono, "Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum," *Jurnal Kolaboratif Sains*, vol. 6, no. 12, pp. 2081–2092, 2023, doi: 10.56338/jks.v6i12.4938.
- [7] M. Khoiruddin, A. Junaidi, and W. A. Saputra, "Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network," *Journal of Dinda*, vol. 2, no. 1, pp. 37–45, 2022, doi: <https://doi.org/10.20895/dinda.v2i1.341>.
- [8] R. Shinta, Jasrilb, M. Irsyad, F. Yanto, and S. Sanjaya, "Klasifikasi Citra Penyakit Daun Tanaman Padi Menggunakan CNN dengan Arsitektur VGG-19," *Jurnal Sains dan Informatika*, vol. 9, no. 1, pp. 37–45, Apr. 2023, doi: 10.22216/jsi.v9i1.2175.
- [9] R. Suciani, D. A. Anugra, E. Faisal, and D. Nuswantoro, "Deteksi Penyakit Daun Padi Menggunakan Deep Learning dengan Arsitektur CNN (Detection of Rice Leaf Disease Using Deep Learning with CNN Architecture)," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 8, no. 5, 2025, doi: <https://doi.org/10.31539/9112kc41>.
- [10] T. D. A. R. Putra and Y. F. Riti, "Implementasi Arsitektur MobileNetV2 untuk Klasifikasi Rumah Adat Berbasis Android," *Jurnal Sistem dan Teknologi Informasi*, vol. 14, no. 2, pp. 217–222, 2026, doi: 10.26418/justin.v14i2.97977.
- [11] M. M. Nugraha, M. D. F. Saputra, D. A. Fauzan, and E. Y. Puspaningrum, "Augmentasi Data Pengenalan Citra Batik Yogyakarta Menggunakan Pendekatan Random Crop, Rotate, Dan Mixup," *Prosiding Seminar Nasional*

- Informatika Bela Negara*, vol. 5, no. 1, pp. 152–158, 2025, doi: 10.33005/santika.v5i1.680.
- [12] A. Banerjee and A. Chandra, “A comparative study on 2-D convolutional neural network architectures for the detection of cognitive impairment from structural MRI,” *Discover Electronics*, vol. 3, no. 1, p. 8, Jan. 2026, doi: 10.1007/s44291-026-00156-4.
- [13] T. H. Nguyen, T. N. Nguyen, and B. V. Ngo, “A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease,” *AgriEngineering*, vol. 4, no. 4, pp. 871–887, Dec. 2022, doi: 10.3390/agriengineering4040056.
- [14] I. Santoso, A. M. Manurung, and E. R. Subhiyakto, “Comparison of ResNet-50, EfficientNet-B1, and VGG-16 Algorithms for Cataract Eye Image Classification,” *Journal of Applied Informatics and Computing*, vol. 9, no. 2, pp. 284–294, 2025, doi: 10.30871/jaic.v9i2.8968.
- [15] J. Wang, H. Li, G. Huo, C. Li, and Y. Wei, “Multi-Mode Channel Position Attention Fusion Side-Scan Sonar Transfer Recognition,” *Electronics (Switzerland)*, vol. 12, no. 4, Feb. 2023, doi: 10.3390/electronics12040791.
- [16] A. Z. Hibatullaha, M. F. Rahmanb, and A. P. Saric, “Pemanfaatan Metode Convolutional Neural Network (CNN) Dengan Arsitektur MobileNetV2 Untuk Penilaian Kelayakan Rumah,” *ALINIER: Journal of Artificial Intelligence & Applications*, vol. 5, no. 2, pp. 129–139, Nov. 2024, doi: <https://doi.org/10.36040/alinier.v5i2.11061>.
- [17] I. S. Lestari, J. Jumadi, and N. Lukman, “Implementasi Convolutional Neural Network dengan Pre-Trained Model MobileNetV2 untuk Deteksi Kolesterol,” *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 9, no. 2, pp. 173–183, Jul. 2024, doi: 10.36341/rabit.v9i2.4732.
- [18] P. Enkvetchakul and O. Surinta, “Effective Data Augmentation and Training Techniques for Improving Deep Learning in Plant Leaf Disease Recognition,” *Applied Science and Engineering Progress*, vol. 15, no. 3, Jul. 2022, doi: 10.14416/j.asep.2021.01.003.
- [19] S. A. S. Mola, B. O. D. K. Wadu, A. N. Kenlopo, and V. C. K. Tingga, “Perbandingan Arsitektur ResNet50V2, InceptionV3, dan DenseNet121 dalam Klasifikasi Pengenalan Ekspresi Wajah,” *JIKO (Jurnal Informatika dan Komputer)*, vol. 9, no. 2, pp. 285–294, Jun. 2025, doi: 10.26798/jiko.v9i2.1584.
- [20] T. Zhou, X. Ye, H. Lu, X. Zheng, S. Qiu, and Y. Liu, “Dense Convolutional Network and Its Application in Medical Image Analysis,” *Biomed Res. Int.*, vol. 2022, pp. 1–22, 2022, doi: 10.1155/2022/2384830.
- [21] M. S. I. Khan *et al.*, “Accurate brain tumor detection using deep convolutional neural network,” *Comput. Struct. Biotechnol. J.*, vol. 20, pp. 4733–4745, Jan. 2022, doi: 10.1016/j.csbj.2022.08.039.
- [22] Hanisa, A. Kartika, D. Pakpahan, W. Novitasari, Q. R. Ismail, and N. Hayaty, “Penggunaan Convolutional Neural Network (CNN) untuk Menentukan Kesegaran Ikan Bawal Putih,” *Jurnal Sustainable: Jurnal Hasil Penelitian dan Industri Terapan*, vol.

- 13, no. 1, pp. 16–22, 2024, doi: <https://doi.org/10.31629/sustainable.v13i1>.
- [23] O. Harris and M. Andrews, “Effects and results of dropout layer in reducing overfitting with convolutional Neural Networks (CNN),” *World Journal of Advanced Engineering Technology and Sciences*, vol. 13, no. 2, pp. 836–853, 2024, doi: [10.30574/wjaets.2024.13.2.0584](https://doi.org/10.30574/wjaets.2024.13.2.0584).
- [24] A. H. Nasrullah, “Convolutional Neural Network untuk Deteksi Penyakit Paru-Paru Menggunakan Citra Radiografi,” *Journal of Computers, Informatics, and Vocational Education*, vol. 1, no. 2, pp. 37–42, 2024.
- [25] F. Ramadhan and J. Hernadi, “Evaluasi Optimizer Adam dan RMSProp pada Arsitektur VGG-19 Klasifikasi Ekspresi Wajah Manusia,” *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 10, no. 2, pp. 1414–1426, Mar. 2025, doi: [10.29100/jupi.v10i2.6197](https://doi.org/10.29100/jupi.v10i2.6197).
- [26] M. M. Chinthia, E. P. Cynthia, M. Eka, and F. Nursalisah, “Pengaruh Parameter Learning Rate terhadap Konvergensi Model Neural Network dalam Proses Pelatihan,” *Jurnal Ilmu Komputer dan Teknik Informatika*, vol. 1, no. 1, pp. 21–28, 2025, doi: <https://doi.org/10.64803/juikti.v1i1.45>.
- [27] F. R. Valerian, M. Syarief, and D. A. Fatah, “Klasifikasi tingkat obesitas menggunakan metode gbm dan confusion matrix,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 2, pp. 2242–2249, 2025, doi: <https://doi.org/10.36040/jati.v9i2.13062>.
- [28] A. Indrajaya, “Perbandingan Klasifikasi Kacang Kering dengan Algoritma KNN dan SVM Linear,” *Jurnal Komputer dan Informatika*, vol. 20, no. 1, pp. 62–70, 2025.
- [29] N. Safitri, D. Kusnandar, and S. Martha, “Implementasi Algoritma K-Nearest Neighbor Dengan Normalisasi Z-Score Dalam Klasifikasi Penerima Bantuan Sosial Desa Serunai,” *Buletin Ilmiah Mat. Stat. dan Terapannya (Bimaster)*, vol. 13, no. 1, pp. 99–106, 2024, doi: <https://doi.org/10.26418/bbimst.v13i1.74063>.
- [30] N. I. Chaerunnisa and M. Y. T. Sulistyono, “Machine Learning-Based Teacher Performance Classification Using Administrative and Credit Point Assessment (PAK) Data: A Comparative Study of Decision Tree and Naive Bayes,” *Journal of Applied Informatics and Computing (JAIC)*, vol. 10, no. 2, pp. 1853–1863, 2026, doi: <https://doi.org/10.30871/jaic.v10i2.12377>.
- [31] Rahayu, B. Irawan, and O. S. Bachri, “Klasifikasi Sentimen Ulasan Produk Samsung pada Platform E-Commerce Tokopedia Menggunakan Algoritma Naive Bayes,” *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 11, no. 1, pp. 1904–1921, 2026, doi: <https://doi.org/10.36341/rabit.v11i1.7557>.
- [32] L. M. Ni'mah and D. Kurniawan, “Model Klasifikasi Cerdas Gangguan Tidur Berbasis Machine Learning Random Forest pada Data Kesehatan dan Perilaku Harian,” *Technology and Science (BITS)*, vol. 7, no. 3, pp. 1717–1729, 2025, doi: [10.47065/bits.v7i3.8631](https://doi.org/10.47065/bits.v7i3.8631).