

Comparison of ResNet50, ResNet101, and ResNet152 Architectures in Image-Based Rice Leaf Disease Classification

Ardi Setyawan¹⁾, Anindita Septiarini^{2*)}, Andi Tejawati³⁾

¹⁾²⁾³⁾Informatika, Teknik, Universitas Mulawaman

***)Correspondence author:** Anindita Septiarini, anindita@unmul.ac.id, Samarinda, Indonesia

DOI : <https://doi.org/10.37012/jtik.v12i1.3289>

Abstract

Rice leaf diseases are one of the main threat that can reduce rice crop productivity especially if they are not detected at an early stage. Conventional disease identification still has limitations because it relies on visual observation and the experience of farmers. Therefore, this study proposes a rice leaf disease classification approach based on digital images using deep learning methods. This study aims to compare the performance of three Residual Network architectures, namely ResNet50, ResNet101, and ResNet152. The dataset used was collected from three public Kaggle datasets, consisting 7.322 images divided into four classes (healthy, hispa, sheath blight, and brown spot). The dataset was split into training, validation, and testing sets with a ratio of 70:20:10 and processed through image preprocessing and data augmentation. All models were trained using a transfer learning approach with the same training configuration to ensure a fair comparison. Model performance was evaluated with the test sets using loss, accuracy, and confusion matrix analysis. The experimental results show that ResNet101 achieved the best performance with a loss value of 0,0146 and an accuracy of 0,9973. Followed by ResNet50 with an accuracy of 0,9918, and ResNet152 with an accuracy of 0,9837. These results indicate that ResNet101 provides the best balance between network depth and classification performance.

Keywords: Image Classification, Convolutional Neural Network, ResNet, Rice Leaf Diseases, Deep Learning

Abstrak

Penyakit daun padi merupakan salah satu ancaman utama yang dapat menurunkan produktivitas tanaman padi apabila tidak terdeteksi secara dini. Identifikasi penyakit secara konvensional masih memiliki keterbatasan karena bergantung pada pengamatan visual dan pengalaman petani. Oleh karena itu, penelitian ini mengusulkan pendekatan klasifikasi penyakit daun padi berbasis citra digital menggunakan metode deep learning. Penelitian ini bertujuan untuk membandingkan performa tiga arsitektur Residual Network, yaitu ResNet50, ResNet101, dan ResNet152. Dataset yang digunakan berasal dari tiga sumber dataset publik Kaggle dengan total 7.322 citra yang terbagi ke dalam empat kelas (healthy, hispa, sheath blight, dan brown spot). Dataset dibagi menjadi data latih, validasi, dan uji dengan rasio 70:20:10, serta melewati tahap preprocessing dan augmentasi citra. Ketiga model dilatih menggunakan pendekatan transfer learning dengan parameter pelatihan yang sama untuk memastikan perbandingan yang adil. Evaluasi performa dilakukan menggunakan metrik loss dan akurasi dan confusion matrix pada data uji. Hasil pengujian menunjukkan bahwa ResNet101 menghasilkan performa terbaik dengan nilai loss sebesar 0,0146 dan akurasi sebesar 0,9973, diikuti oleh ResNet50 dengan akurasi sebesar 0,9918, dan ResNet152 dengan akurasi sebesar 0,9837. Hasil ini menunjukkan bahwa ResNet101 memberikan keseimbangan terbaik antara kedalaman arsitektur dan performa klasifikasi.

Kata Kunci : Klasifikasi Citra, Convolutional Neural Network, ResNet, Penyakit Daun Padi, Deep Learning

PENDAHULUAN

Padi (*Oryza sativa* L.) merupakan komoditas pangan utama di Indonesia yang memiliki peran strategis dalam menjaga ketahanan pangan nasional. Tingginya ketergantungan masyarakat terhadap beras tercermin dari data konsumsi beras rumah tangga di Indonesia yang mencapai 98,86% pada tahun 2023 (Supriyanto, 2023). Hal ini menuntut peningkatan produktivitas padi secara berkelanjutan. Namun, produktivitas padi sering mengalami penurunan akibat serangan penyakit daun, seperti brown spot, sheath blight, dan hispa yang dapat mengganggu proses fotosintesis serta menurunkan hasil panen apabila tidak ditangani secara dini (Molla dkk., 2020). Oleh karena itu, deteksi penyakit daun padi secara tepat dan cepat menjadi langkah penting untuk meminimalkan kerugian hasil pertanian.

Identifikasi penyakit daun padi secara konvensional umumnya dilakukan melalui pengamatan visual oleh petani atau pakar pertanian. Metode ini memiliki keterbatasan karena bersifat subjektif, bergantung pada pengalaman, serta kurang efisien ketika diterapkan pada area pertanian yang luas. Seiring perkembangan teknologi, pendekatan berbasis computer vision dan deep learning mulai banyak dimanfaatkan untuk melakukan klasifikasi penyakit tanaman secara otomatis, cepat, dan konsisten berbasis citra digital (Pacal dkk., 2024).

Salah satu metode deep learning yang paling banyak digunakan dalam klasifikasi citra adalah Convolutional Neural Network (CNN). CNN dirancang untuk mengekstraksi fitur visual secara otomatis melalui operasi konvolusi dan pooling, sehingga mampu mempelajari pola, tekstur, serta variasi warna tanpa memerlukan perancangan fitur secara manual. Keunggulan CNN dalam berbagai tugas klasifikasi citra telah banyak dilaporkan dalam berbagai penelitian (Ardiansyah & Tinaliah, 2025; Setyadi dkk., 2024) yang menunjukkan bahwa metode ini efektif dalam menangani permasalahan dengan variasi visual yang kompleks. Kemampuan CNN dalam mengekstraksi fitur secara otomatis dari data citra tanpa memerlukan intervensi manual menjadikannya alat yang sangat efektif untuk pengenalan pola pada citra pertanian (Pranatha dkk., 2024).

Namun, peningkatan kedalaman jaringan CNN sering menghadapi permasalahan degradasi performa dan vanishing gradient. Untuk mengatasi masalah tersebut, Residual

Network (ResNet) diperkenalkan dengan konsep skip connection yang memungkinkan pelatihan jaringan saraf yang sangat dalam secara lebih stabil (He dkk., 2016). Arsitektur ResNet telah banyak diterapkan pada berbagai tugas klasifikasi penyakit tanaman dengan kemampuan ekstraksi fitur yang lebih efektif (Johri dkk., 2024). Dalam penelitian ini, arsitektur ResNet digunakan dengan pendekatan transfer learning sehingga model dapat mengenali pola dasar seperti tekstur, bentuk, dan warna secara lebih efektif (Hasanah dkk., 2023).

Arsitektur ResNet memiliki beberapa varian dengan jumlah lapisan dan parameter yang berbeda, seperti ResNet50, ResNet101, dan ResNet152 yang masing-masing terdiri dari 50, 101, dan 152 lapisan. Perbedaan kedalaman jaringan tersebut memengaruhi kompleksitas proses pembelajaran serta kemampuan model dalam mengekstraksi fitur visual. Arsitektur dengan jumlah lapisan yang dalam memungkinkan model mempelajari fitur yang lebih kompleks dan detail tetapi memerlukan waktu pelatihan serta sumber daya komputasi yang lebih besar (Hasanah dkk., 2023).


Oleh karena itu, penelitian ini bertujuan untuk membandingkan performa tiga varian arsitektur ResNet, yaitu ResNet50, ResNet101, dan ResNet152 dengan pendekatan transfer learning guna mengidentifikasi model yang paling optimal dalam mengklasifikasikan penyakit daun padi secara akurat dan konsisten.

METODE PENELITIAN

Bagian ini menjelaskan metode yang digunakan pada penelitian ini meliputi perancangan, pengumpulan dan persiapan data, tahapan preprocessing, pengembangan model menggunakan arsitektur ResNet, dan evaluasi performa model.

Perancangan Penelitian

Perancangan penelitian menjelaskan kerangka kerja keseluruhan dari penelitian ini untuk memastikan setiap tahapan dilakukan secara terstruktur dan sistematis. Penelitian dimulai dari pengumpulan data, preprocessing, dan pemodelan, kemudian dilanjutkan dengan tahap evaluasi model. Alur kerja penelitian secara keseluruhan dapat dilihat pada Gambar 1.



Gambar 1. Alur Kerja Penelitian

Pengumpulan Data

Penelitian ini menggunakan dataset publik yang diperoleh dari tiga sumber dataset Kaggle yang digabungkan menjadi satu dataset. Seluruh citra pada dataset digunakan sebagai data input dalam proses pelatihan dan pengujian model klasifikasi penyakit daun padi. Contoh citra daun padi dari masing-masing kelas ditunjukkan pada Gambar 2, sedangkan rincian spesifikasi dataset disajikan pada Tabel 1, dan distribusi jumlah citra pada setiap kelas ditampilkan pada Tabel 2.



Gambar 2. Sampel Citra Daun Padi dari Dataset Publik

Tabel 1. Rincian Spesifikasi Dataset Publik

Spesifikasi	Rentang/Nilai Tunggal
Format	JPG
Ukuran File	46 – 2.179 kb
Resolusi	512 × 500 – 4.284 × 4.284 piksel
Total Citra	7.322 Citra

Tabel 2. Jumlah Citra pada Tiap Kelas Dataset Publik

Kelas	Jumlah Citra
<i>Brown Spot</i>	1.883 Citra
<i>Healthy</i>	1.856 Citra
<i>Hispa</i>	1.793 Citra
<i>Sheath Blight</i>	1.790 Citra

Preprocessing

Dataset yang digunakan melewati tahapan data splitting, terbagi menjadi tiga subsets: 70% training, 20% validation, dan 10% testing yang menghasilkan 5.125 data train, 1.463 data validation dan 734 data test. Pembagian rasio data ini bertujuan untuk memastikan proses pelatihan model berlangsung secara efektif (Rosalina dkk., 2025). Hasil pembagian data dapat dilihat pada Tabel 3.

Tabel 3. Jumlah Citra pada Tiap Subset


Subset	Jumlah Citra
<i>Train</i>	5.125 Citra
<i>Validation</i>	1.463 Citra
<i>Test</i>	734 Citra

Setelah dataset dibagi, seluruh citra melewati beberapa tahapan preprocessing untuk menjaga konsistensi dan meningkatkan performa model (Zuhari dkk., 2022). Tahapan ini meliputi resizing, normalisasi (rescaling), dan augmentasi data. Adapun teknik preprocessing yang diterapkan yaitu, setiap citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan dimensi input standar arsitektur ResNet. Nilai piksel kemudian dinormalisasi dari rentang [0, 255] menjadi [0, 1] untuk menstabilkan proses pelatihan model (Doggalli dkk., 2025). Selanjutnya, data latih diaugmentasi menggunakan fungsi ImageDataGenerator dari library Keras. Fungsi ImageDataGenerator memungkinkan augmentasi secara langsung saat proses pelatihan, sehingga variasi citra dihasilkan secara

acak pada tiap epoch pelatihan tanpa menambah jumlah total dataset. Teknik augmentasi yang diterapkan pada data latih meliputi brightness (0,6 – 1,2), rotation (20°), zoom (0,2), serta horizontal dan vertical flipping.

Modeling

Penelitian ini menggunakan arsitektur Residual Network (ResNet) sebagai feature extractor dengan tiga varian, yaitu ResNet50, ResNet101, dan ResNet152. ResNet diperkenalkan oleh He dkk. (2016) dengan konsep shortcut connection atau skip connection yang memungkinkan pelatihan jaringan saraf yang sangat dalam menjadi lebih stabil. Model dilatih menggunakan pendekatan transfer learning dari ImageNet untuk mengekstraksi fitur visual umum seperti tepi, warna, dan tekstur, yang terbukti efektif dalam berbagai tugas klasifikasi citra (Hasanah dkk., 2023; Johri dkk., 2024). Setiap model dimodifikasi dengan menambahkan lapisan klasifikasi untuk meningkatkan performa dan memungkinkan klasifikasi penyakit daun padi. Untuk menjaga konsistensi dan keadilan dalam perbandingan, ketiga model menggunakan struktur konfigurasi yang sama. Struktur keseluruhan model yang digunakan ditunjukkan pada Gambar 3.



Gambar 3. Tampilan Struktur Model

Seperti yang ditunjukkan pada Gambar 3, arsitektur model terbagi atas dua bagian utama, yaitu base model ResNet dan lapisan klasifikasi tambahan. Lapisan fully connected bawaan ResNet dihilangkan (`include_top=False`) dan digantikan dengan lapisan klasifikasi khusus agar sesuai dengan empat kelas penyakit daun padi. Model menerima masukan citra berukuran 224x224 piksel dengan tiga kanal warna (RGB), kemudian fitur diekstraksi menggunakan arsitektur ResNet. Setelah tahap ekstraksi fitur, ditambahkan lapisan Global Average Pooling 2D, diikuti oleh lapisan Dense dengan 256 neuron dan fungsi aktivasi ReLU, Batch Normalization, serta Dropout dengan tingkat 0,5 untuk mengurangi overfitting. Lapisan keluaran akhir menggunakan Dense layer dengan empat neuron dan fungsi aktivasi Softmax untuk menghasilkan probabilitas klasifikasi pada setiap kelas penyakit daun padi (Sukmawardani dkk., 2024).

Evaluasi Model

Pada penelitian ini, evaluasi menggunakan dua pendekatan utama, yaitu performance metrics dan confusion matrix. Performance metrics digunakan dengan melihat akurasi dan loss untuk menilai kinerja keseluruhan serta stabilitas proses pelatihan dari setiap model ResNet. Akurasi menunjukkan proporsi data yang berhasil diklasifikasikan dengan benar, sedangkan loss menunjukkan tingkat kesalahan prediksi model, sehingga dapat memberikan gambaran mengenai kemampuan model dalam mempelajari pola citra dan kemampuan generalisasi pada citra yang belum pernah dilihat (Elharrouss dkk., 2025).

Selain itu, confusion matrix digunakan untuk menganalisis hasil klasifikasi secara lebih detail dengan membandingkan label aktual dan prediksi pada setiap kelas penyakit. Matriks ini merangkum prediksi benar dan salah ke dalam empat komponen, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Nilai-nilai tersebut menjadi dasar perhitungan metrik evaluasi seperti akurasi, presisi, recall, dan F1-Score (Muhlashin & Stefanie, 2023).

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$
$$Presisi = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall}$$

Akurasi mengukur proporsi prediksi yang benar terhadap seluruh data, sedangkan presisi dan recall masing-masing menunjukkan kemampuan model dalam meminimalkan kesalahan klasifikasi dan mendeteksi kelas yang relevan secara tepat. F1-Score merupakan nilai rata-rata harmonik dari Presisi dan Recall yang memberikan ukuran kinerja model secara seimbang. Secara keseluruhan, metrik-metrik tersebut digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan citra penyakit daun padi secara efektif dan konsisten (Rainio dkk., 2024).

HASIL DAN PEMBAHASAN

Pada tahap ini dilakukan implementasi sistem klasifikasi penyakit daun padi berdasarkan citra dengan menggunakan arsitektur ResNet50, ResNet101, dan ResNet152. Proses pengembangan model dilakukan menggunakan platform Visual Studio Code dengan bahasa pemrograman Python dan dukungan library TensorFlow dan Keras. Konfigurasi pelatihan menggunakan learning rate sebesar 0,0001, batch size 32, serta optimizer Adam untuk mengoptimalkan proses update bobot model. Dataset dibagi menjadi tiga bagian, yaitu 70% training, 20% validation, dan 10% testing. Ketiga model dilatih selama 50 epoch dengan konfigurasi dan parameter pelatihan yang sama untuk memastikan evaluasi yang konsisten dan adil.

Pada setiap model, ditambahkan lapisan klasifikasi tambahan yang terdiri dari Global Average Pooling 2D, lapisan Dense dengan 256 neuron dan aktivasi ReLU, Batch Normalization, serta dropout dengan tingkat 0,5, dan lapisan output berupa Softmax. Selain itu, selama proses pelatihan diterapkan mekanisme callback berupa early stopping dengan melihat akurasi validasi model selama pelatihan. Mekanisme ini digunakan untuk mencegah terjadinya overfitting serta meningkatkan efisiensi proses pelatihan.

Evaluasi dilakukan dengan menggunakan performance metrics untuk menilai performa model secara keseluruhan. Selain itu, confusion matrix digunakan untuk menganalisis kemampuan model dalam mengklasifikasikan setiap kelas penyakit daun padi secara lebih rinci. Kombinasi kedua pendekatan ini memungkinkan evaluasi yang tidak hanya berfokus pada performa model secara umum, tetapi juga pada pola kesalahan klasifikasi pada masing-masing kelas.

Analisis Performa Model

Tabel 4 menyajikan hasil pengujian performa ketiga model dalam klasifikasi penyakit daun padi. Pengujian dilakukan menggunakan data test final sebanyak 734 citra yang belum pernah dilihat oleh model selama proses pelatihan. Evaluasi performa menampilkan nilai akurasi dan loss model ketika diuji dengan menggunakan data validasi dan data uji. Dengan ini evaluasi ini memberikan gambaran menyeluruh terhadap kemampuan klasifikasi model. Hasil evaluasi dapat dilihat pada Tabel 4.

Tabel 4. Evaluasi Model ResNet

Model	Akurasi		Loss	
	Validation Set	Test Set	Validation Set	Test Set
ResNet50	0,9918	0,9918	0,0260	0,0369
ResNet101	0,9925	0,9973	0,0181	0,0146
ResNet152	0,9768	0,9837	0,0667	0,0594

Berdasarkan Tabel 4, seluruh arsitektur ResNet yang diuji menunjukkan performa klasifikasi yang tinggi. Akurasi pada ketiga model berada di atas 97% pada data validasi dan data uji, sehingga mengindikasikan bahwa pendekatan deep learning berbasis ResNet efektif untuk klasifikasi penyakit daun padi.

ResNet50 menunjukkan kinerja yang stabil dengan akurasi 0,9918 pada data validasi dan data uji, meskipun nilai loss pada data uji meningkat sedikit dibandingkan dengan data validasi. Hal ini mengindikasikan bahwa meskipun ResNet50 mampu melakukan klasifikasi dengan tingkat ketepatan yang tinggi.


ResNet101 menghasilkan performa terbaik dibandingkan dua model lainnya. Pada data uji, ResNet101 mencapai akurasi tertinggi sebesar 0,9973 dengan nilai loss terendah


sebesar 0,0146. Hal ini menunjukkan bahwa ResNet101 memiliki kemampuan generalisasi yang sangat baik terhadap data yang belum pernah dilihat sebelumnya.

Sementara itu, ResNet152 memperoleh performa terendah di antara ketiga model dengan akurasi 0,9768 pada data validasi dan 0,9837 pada data uji, serta nilai loss yang relatif lebih tinggi. Hasil ini menunjukkan bahwa penambahan kedalam layer model tidak selalu menjamin peningkatan performa model dan bahkan dapat menyebabkan penurunan performa akibat kompleksitas model yang terlalu tinggi.

Analisis Confusion Matrix

Tahap ini dilakukan untuk menganalisis performa klasifikasi secara lebih rinci pada setiap kelas penyakit daun padi. Analisis confusion matrix memungkinkan identifikasi pola kesalahan prediksi yang tidak dapat terlihat hanya dari nilai akurasi dan loss. Visualisasi confusion matrix untuk ResNet50, ResNet101, dan ResNet152 dapat dilihat pada Gambar 4.





(c)

Gambar 4. Visualisasi Confusion Matrix Model ResNet: (a) ResNet50, (b) ResNet101.
dan (c) ResNet152

Untuk memberikan analisis yang lebih rinci, hasil confusion matrix ditunjukkan dalam bentuk True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Nilai TP menunjukkan jumlah citra yang diklasifikasikan secara benar pada suatu kelas. Nilai FP dan FN menunjukkan kesalahan klasifikasi dan nilai TN menunjukkan jumlah citra yang dikenali dengan benar sebagai bukan kelas tersebut.

Pada Gambar 4 (a), ResNet50 mampu mengklasifikasikan sebagian besar kelas secara tepat, namun masih terdapat kesalahan klasifikasi. Kelas brown spot memiliki nilai TP = 186, FN = 3, FP = 1, dan TN = 543. Pada kelas Healthy diperoleh TP = 184, FN = 1, FP = 3, dan TN = 545. Sementara itu kelas Hispa memiliki TP = 180, FN = 0, FP = 1, dan TN = 525, dan terakhir kelas Sheath Blight memiliki TP = 178, FN = 1, FP = 0, dan TN = 554. Nilai TP yang tinggi serta nilai FN dan FP yang rendah menunjukkan bahwa ResNet50 mampu melakukan klasifikasi dengan baik meskipun masih terdapat kesalahan klasifikasi antar kelas.

Pada Gambar 4 (b), ResNet101 memiliki performa klasifikasi terlihat paling optimal. Hampir seluruh citra pada setiap kelas terklasifikasi dengan benar. Kelas Brown Spot memiliki nilai TP = 188, FN = 1, FP = 0, dan TN = 545. Pada kelas Brown Spot diperoleh TP = 188, FN = 1, FP = 1, dan TN = 547. Kelas Healthy memiliki nilai TP = 185, FN = 1, FP = 1, dan TN = 547. Kelas Hispa memiliki TP = 180, FN = 0, FP = 1, dan TN = 553, sedangkan kelas Sheath Blight memiliki TP = 179, FN = 0, FP = 0, dan TN = 555. Nilai FN dan FP yang sangat kecil menunjukkan bahwa ResNet101 memiliki kemampuan klasifikasi dan generalisasi yang sangat baik dalam membedakan setiap kelas penyakit daun padi.

Sementara itu, pada Gambar 4 (c), ResNet152 menunjukkan jumlah kesalahan klasifikasi yang lebih tinggi dibandingkan dua model lainnya. Kelas Brown Spot memiliki nilai TP = 184, FN = 5, FP = 1, dan TN = 554. Kelas Healthy memiliki TP = 185, FN = 1, FP = 5, dan TN = 543. Kelas Hispa memiliki TP = 180, FN = 0, FP = 6, dan TN = 548, sedangkan kelas Sheath Blight memiliki TP = 173, FN = 6, FP = 0, dan TN = 555. ResNet152 memiliki nilai FP dan FN pada beberapa kelas yang lebih tinggi dari dua model sebelumnya menunjukkan bahwa ResNet152 mengalami lebih banyak kesalahan klasifikasi dibandingkan model lainnya.

Secara keseluruhan, hasil visualisasi confusion matrix menunjukkan bahwa ketiga model ResNet mampu melakukan klasifikasi penyakit daun padi dengan tingkat ketepatan yang sangat tinggi. Di antara ketiga model tersebut, ResNet101 menunjukkan performa paling konsisten dengan jumlah kesalahan klasifikasi yang paling rendah pada seluruh kelas. Kesalahan klasifikasi yang ada pada ResNet50 dan ResNet152 umumnya terjadi pada kelas dengan karakteristik visual yang relatif mirip seperti Brown Spot dan Healthy atau Sheath Blight dan Hispa. Hasil ini menguatkan hasil evaluasi metrik performa sebelumnya bahwa ResNet101 memiliki keseimbangan terbaik antara kedalaman arsitektur dan kemampuan generalisasi dalam mengklasifikasikan penyakit daun padi.

Untuk melengkapi analisis visual tersebut, performa setiap model pada masing-masing kelas juga disajikan dalam bentuk tabel classification report yang memuat nilai Precision, Recall, dan F1-Score yang dapat dilihat pada Tabel 5.

Tabel 5. Precision, Recall, dan F1-score dari tiap Kelas Penyakit di Ketiga Model ResNet

Model	Kelas	Precision	Recall	F1-Score
ResNet50	<i>Brown Spot</i>	0,99	0,98	0,99
	<i>Healthy</i>	0,98	0,99	0,99
	<i>Hispa</i>	0,99	1,00	1,00
	<i>Sheath Blight</i>	0,99	0,99	0,99
ResNet101	<i>Brown Spot</i>	1,00	0,99	1,00
	<i>Healthy</i>	0,99	0,99	0,99
	<i>Hispa</i>	0,99	1,00	1,00
	<i>Sheath Blight</i>	1,00	1,00	1,00
ResNet152	<i>Brown Spot</i>	0,99	0,97	0,98
	<i>Healthy</i>	0,97	0,99	0,98
	<i>Hispa</i>	0,97	1,00	0,98
	<i>Sheath Blight</i>	1,00	0,97	0,98

Berdasarkan classification report pada Tabel 5, seluruh model ResNet menunjukkan performa yang sangat baik pada keempat kelas penyakit daun padi dengan nilai precision, recall, dan F1-Score berada di atas 0,97. Hal ini menunjukkan bahwa arsitektur ResNet mampu mengenali setiap kelas penyakit dengan tingkat ketepatan dan konsistensi yang sangat baik.

Pada ResNet50, performa model relatif stabil di seluruh kelas dengan nilai F1-score sebesar 0,99 untuk kelas Brown Spot, Healthy, dan Sheath Blight, serta nilai sempurna (1,00) pada kelas Hispa. Nilai precision dan recall yang tinggi menunjukkan bahwa model ResNet50 mampu mengklasifikasi penyakit daun padi dengan tepat, meskipun masih terdapat sedikit ketidakseimbangan pada beberapa kelas.

ResNet101 menunjukkan performa yang paling optimal dan konsisten. Kelas Brown Spot dan Sheath Blight masing-masing memperoleh nilai precision sebesar 1,00 dengan recall 0,99 pada Brown Spot dan 1,00 pada Sheath Blight. Selain itu, kelas Hispa dan Sheath Blight mencapai nilai F1-score sempurna (1,00). Hal ini menunjukkan bahwa hampir seluruh citra pada kelas tersebut berhasil diklasifikasikan dengan benar. Konsistensi nilai metrik pada seluruh kelas menunjukkan bahwa ResNet101 memiliki performa yang terbaik dan paling seimbang.

Sementara itu, ResNet152 menunjukkan performa yang sedikit lebih rendah dibandingkan dua model lainnya. Nilai recall pada kelas Brown Spot (0,97) dan Sheath Blight (0,97) menunjukkan bahwa masih terdapat sejumlah citra yang tidak terklasifikasi dengan benar. Meskipun demikian, nilai F1-score yang tetap tinggi (0,98) menunjukkan bahwa model ini masih mampu melakukan klasifikasi secara efektif, namun kurang optimal dibandingkan dengan ResNet101.

KESIMPULAN DAN REKOMENDASI

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa arsitektur ResNet50, ResNet101, dan ResNet152 mampu mengklasifikasikan penyakit daun padi dengan tingkat akurasi yang sangat tinggi. Hasil evaluasi dengan menggunakan metrik akurasi, loss, serta confusion matrix menunjukkan bahwa ResNet101 menjadi model dengan performa yang terbaik dengan nilai akurasi tertinggi dan nilai loss yang terendah serta paling konsisten saat melakukan klasifikasi seluruh kelas penyakit ditandai dengan keseimbangan yang optimal antara precision, recall, dan F1-score. Hasil ini mengindikasikan bahwa kedalaman jaringan yang menengah pada ResNet101 mampu menghasilkan model yang lebih efektif dibandingkan ResNet50 maupun ResNet152.

Sebagai saran untuk penelitian selanjutnya, disarankan untuk melatih dan menguji model pada dataset yang lebih besar dan beragam untuk meningkatkan kemampuan generalisasi sistem. Selain itu, pengembangan model dapat dilakukan dengan mengimplementasi metode hiperparameter untuk meningkatkan performa klasifikasi. Untuk mendukung penerapan langsung di lapangan, penelitian selanjutnya juga dapat mengeksplorasi penggunaan arsitektur yang ringan seperti MobileNet agar model dapat diintegrasikan langsung pada aplikasi mobile, sehingga petani dapat melakukan deteksi penyakit daun padi secara langsung di lapangan.

REFERENSI

- Ardiansyah, A., & Tinaliah. (2025). Classification of Indonesian batik patterns using convolutional neural network with MobileNetV3 architecture. *Jurnal Teknologi Informatika dan Komputer*, 12(1), 38–53. <https://doi.org/10.37012/jtik.v12i1.3205>
- Doggalli, R., Deep, A., Naik, R. V., Achari, V. B., Muttagi, V., & Kulkarni, U. (2025). Early detection of diabetic retinopathy using ResNet-18. *SCITEPRESS*, 81–90. <https://doi.org/10.5220/0013609200004664>
- Elharrouss, O., Mahmood, Y., Bechqito, Y., Serhani, M. A., Badidi, E., Riffi, J., & Tairi, H. (2025). Task-based loss functions in computer vision: A comprehensive review. 1–36. <http://arxiv.org/abs/2504.04242>
- Hasanah, S. A., Pravitasari, A. A., Abdullah, A. S., Yulita, I. N., & Asnawi, M. H. (2023). A deep learning review of ResNet architecture for lung disease identification in CXR image. *Applied Sciences (Switzerland)*, 13(24). <https://doi.org/10.3390/app132413111>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Microsoft Research*, 770–778. <http://image-net.org/challenges/LSVRC/2015/>
- Johri, P., Kim, S. K., Dixit, K., Sharma, P., Kakkar, B., Kumar, Y., Shafi, J., & Ijaz, M. F. (2024). Advanced deep transfer learning techniques for efficient detection of cotton plant diseases. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1441117>
- Molla, K. A., Karmakar, S., Molla, J., Bajaj, P., Varshney, R. K., Datta, S. K., & Datta, K. (2020). Understanding sheath blight resistance in rice: The road behind and the road ahead. *Plant Biotechnology Journal*, 18(4), 895–915. <https://doi.org/10.1111/pbi.13312>
- Muhlashin, M. N. I., & Stefanie, A. (2023). Klasifikasi penyakit mata berdasarkan citra fundus menggunakan YOLO v8. *Jurnal Mahasiswa Teknik Informatika*, 7(2), 1363.
- Pacal, I., Kunduracioglu, I., Alma, M. H., Deveci, M., Kadry, S., Nedoma, J., Slany, V., & Martinek, R. (2024). A systematic review of deep learning techniques for plant

- diseases. *Artificial Intelligence Review*, 57(11). <https://doi.org/10.1007/s10462-024-10944-7>
- Pranatha, M. D., Maricar, M. A., & Setiawan, G. H. (2024). Implementasi arsitektural ResNet-34 dalam klasifikasi gambar penyakit pada daun kentang. *Jurnal Teknologi dan Sistem Informasi Bisnis*, 6(3), 575–580. <https://doi.org/10.47233/jteksis.v6i3.1431>
- Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-56706-x>
- Rosalina, R., Husodo, A. Y., & Wijaya, I. G. P. S. (2025). Development of a convolutional neural network method for classifying ripeness levels of servo variety tomatoes. *Jurnal Teknik Informatika (JUTIF)*, 6(2), 501–520. <https://doi.org/10.52436/1.jutif.2025.6.2.4168>
- Setyadi, R. A., Rahman, S., Manurung, D., Hasanah, M., & Indrawati, A. (2024). Implementasi transfer learning untuk klasifikasi penyakit pada daun cabai menggunakan CNN. *Jurnal Teknologi Informasi*, 5(2). <https://doi.org/10.46576/djtechno>
- Sukmawardani, R., Nurpulaela, L., & Rahmadewi, R. (2024). Implementasi arsitektur ResNet152 untuk klasifikasi uang kertas rupiah dengan metode transfer learning. *Jurnal Mahasiswa Teknik Informatika*, 8(4), 5650–5657.
- Supriyanto, S. (2023). *Pengeluaran untuk konsumsi penduduk Indonesia* (A. Chamami, B. Setiawam, & R. Nainggolan, Ed.; Vol. 27). Badan Pusat Statistik.
- Zuhari, A. B., Maulana, D. I., & Maheswara, E. S. (2022). Optimation image classification pada ikan hiu dengan metode convolutional neural network dan data augmentasi. *Jurnal TIKA*, 7, 1–11.