

Densenet201 Feature Extraction With Soft Voting Ensemble For Accurate Rice Leaf Disease Classification

Nelly Khairani Daulay¹⁾; Novi Lestari²⁾; Rusdiyanto³⁾

^{1,2)}Department of Computer System Engineering, Faculty of Engineering Science, Universitas Bina Insan, Lubuk Linggau

³⁾ Department of Informatics, Faculty of Engineering Science, Universitas Bina Insan, Lubuk Linggau
Email: ¹⁾ nellydaulay.univbinainsan.ac.id

How to Cite :

Daulay, N, K., Lestar, N., Rusdiyanto . (2026). Densenet201 Feature Extraction With Soft Voting Ensemble For Accurate Rice Leaf Disease Classification. Jurnal Media Computer Science, 5(3).

ARTICLE HISTORY

Received [17 Juni 2026]

Revised [20 Juli 2026]

Accepted [23 Juli 2026]

KEYWORDS

Plant Leaf Disease, Densenet201, Feature Extraction, Voting Ensemble, Support Vector Machine, Image Classification.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Penyakit pada daun padi merupakan salah satu faktor utama yang menyebabkan penurunan produktivitas pertanian dan kerugian ekonomi bagi petani. Identifikasi penyakit secara manual umumnya memerlukan keahlian khusus dan sering kali sulit dilakukan secara cepat di lapangan. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit daun padi berbasis deep learning dan machine learning menggunakan DenseNet201 sebagai ekstraktor fitur serta metode Voting Ensemble sebagai classifier. Dataset yang digunakan terdiri dari 1.470 citra daun padi yang terbagi ke dalam lima kelas, yaitu Bacterial Leaf Blight, Brown Spot, Healthy Leaf, Leaf Blast, dan Tungro. Data dibagi menggunakan metode stratified split dengan proporsi 80% data pelatihan, 10% data validasi, dan 10% data pengujian. Augmentasi citra diterapkan pada data pelatihan sehingga jumlah sampel meningkat menjadi 7.056 citra. Selanjutnya, DenseNet201 digunakan untuk mengekstraksi fitur citra menjadi vektor fitur berdimensi 1.920 yang kemudian diklasifikasikan menggunakan Logistic Regression, Support Vector Machine (SVM), Hard Voting, dan Soft Voting. Hasil pengujian menunjukkan bahwa Logistic Regression memperoleh akurasi sebesar 95,24%, sedangkan SVM mencapai akurasi sebesar 95,92%. Metode Hard Voting menghasilkan akurasi sebesar 95,24%, sementara Soft Voting memperoleh performa terbaik dengan akurasi 95,92%, precision 95,75%, recall 95,70%, F1-score 95,71%, dan ROC-AUC 99,76%. Selain itu, model terbaik berhasil diimplementasikan dalam aplikasi berbasis Streamlit untuk melakukan identifikasi penyakit daun padi secara otomatis. Hasil penelitian menunjukkan bahwa kombinasi DenseNet201 dan Soft Voting mampu menghasilkan sistem klasifikasi penyakit daun padi yang akurat dan berpotensi digunakan sebagai alat bantu deteksi dini pada sektor pertanian.

ABSTRACT

Rice leaf diseases are one of the major factors contributing to reduced agricultural productivity and economic losses for farmers. Manual disease identification generally requires expert knowledge and is often difficult to perform efficiently in field conditions. Therefore, this study aims to develop a rice leaf disease classification system by combining DenseNet201 as a feature extractor and a Voting Ensemble approach as the classifier. The dataset consisted of 1,470 rice leaf images categorized into five classes: Bacterial Leaf Blight, Brown Spot, Healthy

Leaf, Leaf Blast, and Tungro. The dataset was divided using a stratified split strategy into 80% training data, 10% validation data, and 10% testing data. Image augmentation was applied only to the training set, increasing the number of training samples to 7,056 images. DenseNet201 was employed to extract image features into 1,920-dimensional feature vectors, which were subsequently classified using Logistic Regression, Support Vector Machine (SVM), Hard Voting, and Soft Voting. Experimental results showed that Logistic Regression achieved an accuracy of 95.24%, while SVM achieved 95.92%. Hard Voting obtained an accuracy of 95.24%, whereas Soft Voting achieved the best performance with an accuracy of 95.92%, precision of 95.75%, recall of 95.70%, F1-score of 95.71%, and ROC-AUC of 99.76%. Furthermore, the best-performing model was deployed in a Streamlit-based application for automatic rice leaf disease identification. The results demonstrate that the combination of DenseNet201 and Soft Voting provides an accurate and effective approach for rice leaf disease classification and has strong potential as an early disease detection tool in agriculture.

PENDAHULUAN

Padi (*Oryza sativa*) merupakan komoditas pangan utama di Indonesia dan menjadi makanan pokok sebagian besar masyarakat. Oleh karena itu, produktivitas padi sangat penting untuk menjaga ketahanan pangan nasional. Namun, serangan hama dan penyakit masih menjadi kendala besar dalam budidaya padi dan dapat menyebabkan kehilangan hasil panen yang cukup tinggi (Khoiruddin et al., 2022). Sejumlah penelitian juga menunjukkan bahwa penurunan produksi padi akibat penyakit masih menjadi permasalahan yang terus berulang sehingga diperlukan upaya deteksi dini yang lebih efektif (Kusuma et al., 2025), (Ulfi et al., 2025).

Salah satu masalah yang sering muncul adalah penyakit pada daun padi. Penyakit seperti Bacterial Leaf Blight, Brown Spot, Leaf Blast, dan Tungro dapat menghambat pertumbuhan tanaman serta menurunkan hasil panen (Milano, 2024), (Adiana et al., 2025). Jika tidak dikenali sejak awal, penyakit tersebut dapat menimbulkan kerugian yang lebih besar bagi petani (Maulana et al., 2025). Selain itu, beberapa penelitian juga menunjukkan bahwa penyakit daun padi memiliki karakteristik visual yang beragam sehingga membutuhkan metode klasifikasi yang mampu membedakan tiap kelas secara akurat (Kusuma et al., 2025), (Ulfi et al., 2025).

Selama ini, identifikasi penyakit padi masih banyak dilakukan secara manual. Cara ini membutuhkan pengalaman pakar dan sering kali sulit diterapkan secara cepat di lapangan. Kondisi tersebut membuat petani berisiko salah mengenali gejala penyakit dan melakukan penanganan yang kurang tepat (Putra Pranjaya et al., 2024). Keterbatasan ini menunjukkan bahwa diperlukan sistem otomatis yang dapat membantu proses identifikasi penyakit secara lebih cepat, praktis, dan konsisten (Kusuma et al., 2025), (Ulfi et al., 2025).

Perkembangan Computer Vision dan Deep Learning membuka peluang untuk mendeteksi penyakit padi secara otomatis melalui citra daun. Metode Convolutional Neural Network (CNN) telah menunjukkan hasil yang baik dalam klasifikasi penyakit padi. Beberapa penelitian bahkan melaporkan akurasi yang tinggi dengan arsitektur CNN yang berbeda, seperti MobileNetV2 (Eko Fuji Pangestu & Bambang Irawan, 2026), ResNet50V2 (Maulana et al., 2025), dan CNN sederhana (Moh. Heri Susanto et al., 2025). Penelitian lain juga menunjukkan bahwa CNN dapat diimplementasikan dalam aplikasi berbasis Android untuk mendukung deteksi penyakit padi secara lebih mudah digunakan oleh petani (Kusuma et al., 2025), (Ulfi et al., 2025).

Meski demikian, sebagian besar penelitian dalam deteksi penyakit daun tanaman masih menggunakan CNN sebagai model klasifikasi langsung (Kurniawan, Samsuryadi, et al., 2025a, 2025b). Pendekatan ini memiliki keterbatasan karena bergantung pada satu model saja. Salah satu

alternatif yang dapat digunakan adalah memanfaatkan CNN sebagai feature extractor lalu menggabungkannya dengan metode klasifikasi lain, seperti SVM. Pendekatan hibrida CNN-SVM telah menunjukkan hasil yang baik pada klasifikasi penyakit padi (Adiana et al., 2025). Selain itu, penggunaan model CNN sebagai ekstraktor fitur juga berpotensi menghasilkan representasi yang lebih kuat untuk mendukung proses klasifikasi lanjutan (Kusuma et al., 2025), (Ulfi et al., 2025).

LANDASAN TEORI


Penyakit Daun Padi

Penyakit daun padi merupakan salah satu faktor yang dapat menurunkan produktivitas tanaman padi secara signifikan. Serangan penyakit pada daun mengganggu proses fotosintesis sehingga pertumbuhan tanaman menjadi tidak optimal dan berpotensi menurunkan hasil panen. Identifikasi penyakit secara dini sangat penting untuk mencegah penyebaran penyakit dan meminimalkan kerugian yang dialami petani.

Penelitian ini menggunakan dataset penyakit daun padi yang terdiri dari lima kelas, yaitu Bacterial Leaf Blight, Brown Spot, Leaf Blast, Tungro, dan Healthy Leaf. Bacterial Leaf Blight merupakan penyakit yang disebabkan oleh bakteri *Xanthomonas oryzae* yang ditandai dengan munculnya bercak kekuningan pada tepi daun (Anup Chandra Mondal, 2024). Brown Spot ditandai dengan bercak berwarna coklat berbentuk oval yang dapat menyebar ke seluruh permukaan daun (Bhutia et al., 2025). Leaf Blast disebabkan oleh jamur *Magnaporthe oryzae* dan ditandai dengan bercak berbentuk belah ketupat pada daun (Zhang et al., 2022). Sementara itu, Tungro merupakan penyakit yang disebabkan oleh virus yang menyebabkan perubahan warna daun menjadi kuning hingga oranye serta menghambat pertumbuhan tanaman (Pangga & Sta. Cruz, 2024). Adapun Healthy Leaf merepresentasikan daun padi yang tidak menunjukkan gejala penyakit dan digunakan sebagai kelas pembanding dalam proses klasifikasi.

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu metode Deep Learning yang banyak digunakan dalam bidang pengolahan citra digital dan pengenalan pola (O'Shea & Nash, 2015). CNN dirancang untuk mengekstraksi informasi penting dari citra secara otomatis melalui proses pembelajaran berlapis tanpa memerlukan perancangan fitur secara manual. Kemampuan tersebut menjadikan CNN sebagai salah satu pendekatan yang paling banyak digunakan pada berbagai tugas klasifikasi citra, termasuk identifikasi penyakit tanaman berbasis citra daun.



Gambar 1. Arsitektur CNN

Arsitektur CNN umumnya terdiri atas beberapa lapisan utama, yaitu convolution layer, activation layer, pooling layer, dan fully connected layer (Albawi et al., 2017) yang disajikan secara detail pada gambar 1. Pada convolution layer, citra masukan diproses menggunakan sejumlah filter atau kernel untuk menghasilkan feature map yang merepresentasikan karakteristik tertentu dari citra, seperti tepi, tekstur, warna, maupun bentuk objek. Proses konvolusi dapat dinyatakan sebagai:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i - m, j - n)K(m, n) \quad (1)$$

dengan (i) menyatakan citra masukan, (K) menyatakan kernel konvolusi, dan (S) merupakan hasil proses konvolusi.

Setelah proses konvolusi, hasil feature map diteruskan ke activation layer yang umumnya menggunakan fungsi aktivasi Rectified Linear Unit (ReLU). Fungsi ini bertujuan untuk memperkenalkan sifat nonlinier pada model sehingga mampu mempelajari pola yang lebih kompleks. Fungsi ReLU didefinisikan sebagai:

$$f(x) = \max(0, x) \quad (2)$$

Nilai negatif akan diubah menjadi nol, sedangkan nilai positif dipertahankan sehingga proses komputasi menjadi lebih efisien dan risiko vanishing gradient dapat dikurangi. Lapisan berikutnya adalah pooling layer yang berfungsi untuk mengurangi dimensi data sekaligus mempertahankan informasi penting dari feature map. Salah satu metode yang paling umum digunakan adalah max pooling, yaitu memilih nilai maksimum pada setiap area tertentu dari feature map. Proses ini membantu mengurangi kompleksitas komputasi dan meningkatkan kemampuan generalisasi model terhadap variasi posisi objek dalam citra.

Pada tahap akhir, fitur-fitur yang telah diekstraksi akan diteruskan ke fully connected layer untuk melakukan proses klasifikasi. Lapisan ini menghubungkan seluruh neuron dari lapisan sebelumnya dan menghasilkan probabilitas setiap kelas melalui fungsi aktivasi tertentu, seperti Softmax. Fungsi Softmax dapat dinyatakan sebagai:

$$P(y = i) = \frac{\exp(z_i)}{\sum_{j=1}^C \exp(z_j)} \quad (3)$$

dengan (z_i) merupakan skor untuk kelas ke-(i) dan (C) adalah jumlah kelas.

Keunggulan utama CNN dibandingkan metode pembelajaran mesin tradisional terletak pada kemampuannya melakukan ekstraksi fitur dan klasifikasi secara otomatis dalam satu arsitektur terpadu. Berbagai penelitian menunjukkan bahwa CNN mampu menghasilkan performa yang sangat baik dalam klasifikasi penyakit daun padi karena mampu mempelajari karakteristik visual yang kompleks dari citra daun. Oleh karena itu, CNN menjadi fondasi bagi pengembangan berbagai arsitektur modern, termasuk DenseNet201 yang digunakan dalam penelitian ini sebagai ekstraktor fitur.

Perbedaan karakteristik visual antar penyakit daun padi memungkinkan pemanfaatan teknologi pengolahan citra digital dan kecerdasan buatan untuk melakukan identifikasi secara otomatis. Dengan memanfaatkan citra daun sebagai masukan, sistem klasifikasi dapat mempelajari pola tekstur, warna, dan bentuk gejala penyakit sehingga mampu mengenali jenis penyakit secara lebih cepat dan konsisten dibandingkan metode identifikasi manual.

DenseNet201

DenseNet201 merupakan salah satu arsitektur Convolutional Neural Network (CNN) yang diperkenalkan untuk mengatasi permasalahan hilangnya informasi vanishing gradient dan meningkatkan efisiensi pemanfaatan fitur pada jaringan yang sangat dalam yang diilustrasikan pada gambar 2. DenseNet atau Densely Connected Convolutional Network menghubungkan setiap lapisan dengan seluruh lapisan sebelumnya sehingga informasi yang telah dipelajari pada lapisan awal dapat digunakan kembali oleh lapisan berikutnya (Albelwi, 2022; Vengaiyah & Konda, 2023). Pendekatan ini memungkinkan proses pembelajaran yang lebih efektif dibandingkan arsitektur CNN konvensional yang hanya menghubungkan lapisan secara berurutan.



Gambar 2. Arsitektur DenseNet

Pada DenseNet, keluaran dari setiap lapisan diteruskan ke seluruh lapisan berikutnya melalui mekanisme dense connectivity. Jika $(x_0, x_1, x_2, \dots, x_{l-1})$ merupakan keluaran dari lapisan sebelumnya, maka keluaran pada lapisan ke-(l) dapat dinyatakan sebagai:

$$x_l = H_l([x_0, x_1, x_2, \dots, x_{l-1}]) \quad (4)$$

dengan $(x_0, x_1, x_2, \dots, x_{l-1})$ menyatakan operasi konkatenasi seluruh fitur dari lapisan sebelumnya dan (H_l) merupakan fungsi transformasi yang terdiri atas operasi Batch Normalization, Rectified Linear Unit (ReLU), dan konvolusi.

Berbeda dengan arsitektur CNN tradisional yang hanya memanfaatkan keluaran lapisan sebelumnya, DenseNet memungkinkan setiap lapisan memperoleh akses langsung terhadap seluruh informasi yang telah dipelajari sejak lapisan pertama. Mekanisme tersebut memberikan beberapa keuntungan, yaitu mengurangi hilangnya informasi selama proses propagasi, meningkatkan aliran gradien pada saat pelatihan, memperkuat proses ekstraksi fitur, serta mengurangi jumlah parameter yang diperlukan dibandingkan jaringan yang memiliki kedalaman serupa.

DenseNet201 merupakan salah satu varian DenseNet yang terdiri dari 201 lapisan dan telah dilatih menggunakan dataset ImageNet yang berisi jutaan citra dari berbagai kategori objek. Bobot hasil pelatihan pada ImageNet memungkinkan DenseNet201 digunakan sebagai model transfer learning untuk berbagai permasalahan klasifikasi citra, termasuk identifikasi penyakit tanaman. Pada penelitian ini, DenseNet201 tidak digunakan sebagai model klasifikasi akhir, melainkan sebagai feature extractor untuk menghasilkan representasi fitur dari citra daun padi.

Proses ekstraksi fitur dilakukan dengan menghilangkan lapisan klasifikasi fully connected layer bawaan DenseNet201 dan mempertahankan bagian konvolusinya. Citra daun padi berukuran 224×224 piksel dimasukkan ke dalam jaringan DenseNet201 untuk menghasilkan feature map yang merepresentasikan karakteristik visual penting dari citra. Selanjutnya, feature map tersebut diringkas menggunakan lapisan Global Average Pooling (GAP) sehingga menghasilkan vektor fitur berdimensi tetap.

Global Average Pooling bekerja dengan menghitung nilai rata-rata pada setiap kanal fitur yang dihasilkan oleh lapisan konvolusi terakhir. Jika $F_k(i, j)$ merupakan nilai pada posisi (i, j) dari kanal ke-(k), maka keluaran GAP dapat dihitung menggunakan persamaan:

$$g_k = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_k(i, j) \quad (5)$$

dengan (H) dan (W) menyatakan tinggi dan lebar feature map. Proses ini menghasilkan representasi fitur yang lebih ringkas sekaligus mengurangi risiko overfitting.

Pada penelitian ini, penggunaan DenseNet201 yang dikombinasikan dengan lapisan Global Average Pooling menghasilkan vektor fitur berdimensi 1920 untuk setiap citra daun padi. Vektor fitur tersebut kemudian digunakan sebagai masukan bagi algoritma klasifikasi Logistic Regression dan Support Vector Machine. Dengan demikian, DenseNet201 berperan sebagai ekstraktor fitur yang bertugas mengubah citra daun padi menjadi representasi numerik yang lebih informatif dan mudah diproses oleh model klasifikasi berbasis machine learning.

Ensemble Learning Berbasis Logistic Regression dan Support Vector Machine

Penelitian ini menggunakan dua algoritma klasifikasi sebagai base classifier, yaitu Logistic Regression dan Support Vector Machine (SVM). Kedua algoritma tersebut dipilih karena memiliki karakteristik yang berbeda dalam mempelajari pola data sehingga berpotensi menghasilkan keputusan yang saling melengkapi. Untuk meningkatkan kinerja klasifikasi, hasil prediksi dari kedua model kemudian dikombinasikan menggunakan metode Voting Ensemble (Bin Habib & Tasnim, 2020; Joly et al., 2025).

Logistic Regression merupakan salah satu algoritma klasifikasi yang banyak digunakan untuk memprediksi probabilitas keanggotaan suatu data terhadap kelas tertentu (Dey et al., 2025). Meskipun disebut sebagai regresi, metode ini termasuk dalam kategori algoritma klasifikasi karena menghasilkan keluaran berupa probabilitas kelas.

Pada Logistic Regression, hubungan antara fitur masukan dan probabilitas kelas dimodelkan menggunakan fungsi logistik atau fungsi sigmoid yang didefinisikan sebagai:

$$P(y = 1 | x) = \frac{1}{1 + e^{-z}} \quad (6)$$

dengan:

$$z = \beta_0 + \sum_{i=1}^n \beta_i x_i \quad (7)$$

di mana (x_i) merupakan fitur masukan dan (β_i) adalah parameter model yang dipelajari selama proses pelatihan.

Untuk kasus klasifikasi multikelas, Logistic Regression umumnya menggunakan pendekatan Softmax Regression yang menghasilkan probabilitas untuk setiap kelas. Kelas dengan probabilitas tertinggi akan dipilih sebagai hasil prediksi akhir. Keunggulan Logistic Regression terletak pada kemampuannya menghasilkan probabilitas yang stabil, waktu pelatihan yang relatif cepat, serta kemudahan dalam interpretasi model.

Support Vector Machine (SVM) merupakan algoritma klasifikasi yang bekerja dengan mencari hyperplane optimal yang mampu memisahkan data dari kelas yang berbeda dengan margin maksimum. Semakin besar margin yang diperoleh, semakin baik kemampuan generalisasi model terhadap data baru (Chintyana et al., 2024).

Persamaan dasar hyperplane pada SVM dapat dituliskan sebagai:

$$f(x) = w^T x + b \quad (7)$$

dengan (w) merupakan vektor bobot dan (b) adalah bias model.

Pada data yang tidak dapat dipisahkan secara linear, SVM memanfaatkan fungsi kernel untuk memetakan data ke ruang berdimensi lebih tinggi sehingga batas pemisah dapat dibentuk dengan lebih baik. Dalam penelitian ini digunakan kernel Radial Basis Function (RBF) yang dikenal memiliki kemampuan baik dalam menangani data dengan pola yang kompleks dan nonlinier.

SVM banyak digunakan pada permasalahan klasifikasi citra karena mampu bekerja secara efektif pada data berdimensi tinggi dan memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.

Voting Ensemble

Voting Ensemble merupakan metode ensemble learning yang menggabungkan prediksi dari beberapa model klasifikasi untuk menghasilkan keputusan yang lebih akurat dan stabil dibandingkan penggunaan model tunggal (Adnan et al., 2024; Bin Habib & Tasnim, 2020). Prinsip dasar metode ini adalah memanfaatkan keunggulan masing-masing model sehingga kesalahan prediksi dapat diminimalkan.

Pada penelitian ini digunakan dua skema Voting Ensemble, yaitu Hard Voting dan Soft Voting. Pada Hard Voting, keputusan akhir ditentukan berdasarkan suara mayoritas dari seluruh base classifier (Morgan-Benita et al., 2022). Prediksi kelas yang memperoleh jumlah suara terbanyak akan dipilih sebagai hasil klasifikasi. Secara matematis, Hard Voting dapat dinyatakan sebagai:

$$\text{mode}(y_1, y_2, \dots, y_n) \quad (8)$$

dengan (y_i) merupakan hasil prediksi dari classifier ke-(i).

Berbeda dengan Hard Voting, Soft Voting memanfaatkan probabilitas keluaran dari masing-masing classifier. Probabilitas setiap kelas dijumlahkan kemudian dirata-ratakan untuk menentukan kelas dengan probabilitas terbesar. Persamaan Soft Voting dapat dituliskan sebagai:

$$\frac{1}{n} \sum_{i=1}^n P_i(c) \quad (9)$$

dengan $(P_i(c))$ merupakan probabilitas kelas (c) yang dihasilkan oleh classifier ke-(i). Penelitian ini mengevaluasi kedua metode tersebut untuk mengetahui perbedaan kinerja dan karakteristik hasil klasifikasi penyakit daun padi.

Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan untuk mengukur kemampuan model dalam mengklasifikasikan penyakit daun padi secara akurat (Mallick et al., 2025). Pada penelitian ini, performa model dievaluasi menggunakan beberapa metrik, yaitu Accuracy, Precision, Recall, F1-Score, Confusion Matrix, dan Receiver Operating Characteristic (ROC) (Kurniawan, Siaga, et al., 2025). Penggunaan beberapa metrik evaluasi bertujuan untuk memberikan gambaran yang lebih komprehensif mengenai kemampuan model dalam mengenali setiap kelas penyakit daun padi.

Accuracy merupakan metrik yang menunjukkan proporsi jumlah prediksi yang benar terhadap seluruh data yang diuji. Nilai akurasi dihitung menggunakan persamaan:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (10)$$

dengan TP (True Positive) menyatakan jumlah data positif yang terklasifikasi benar, TN (True Negative) menyatakan jumlah data negatif yang terklasifikasi benar, FP (False Positive) menyatakan jumlah data negatif yang salah diklasifikasikan sebagai positif, dan FN (False Negative) menyatakan jumlah data positif yang salah diklasifikasikan sebagai negatif.

Precision digunakan untuk mengukur tingkat ketepatan model dalam memberikan prediksi terhadap suatu kelas. Nilai precision dihitung menggunakan persamaan:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (11)$$

Semakin tinggi nilai precision, semakin kecil jumlah prediksi positif yang salah dilakukan oleh model.

Recall atau sensitivitas digunakan untuk mengukur kemampuan model dalam menemukan seluruh data yang benar-benar termasuk ke dalam suatu kelas. Nilai recall dihitung menggunakan persamaan:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (12)$$

Nilai recall yang tinggi menunjukkan bahwa model mampu mengenali sebagian besar data yang termasuk ke dalam kelas yang diamati.

F1-Score merupakan rata-rata harmonik antara precision dan recall. Metrik ini digunakan untuk memberikan keseimbangan antara kemampuan model dalam menghasilkan prediksi yang

tepat dan kemampuan dalam menemukan seluruh data yang relevan. Nilai F1-Score dihitung menggunakan persamaan:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (13)$$

Nilai F1-Score yang tinggi menunjukkan bahwa model memiliki keseimbangan yang baik antara precision dan recall.

Confusion Matrix merupakan tabel yang digunakan untuk mengevaluasi performa klasifikasi dengan membandingkan label aktual dan label hasil prediksi model (Xu et al., 2020). Melalui Confusion Matrix, dapat diketahui jumlah prediksi yang benar maupun salah pada setiap kelas. Selain digunakan untuk menghitung berbagai metrik evaluasi, Confusion Matrix juga membantu mengidentifikasi kelas-kelas yang masih sering mengalami kesalahan klasifikasi.

Kurva Receiver Operating Characteristic (ROC) digunakan untuk mengevaluasi kemampuan model dalam membedakan antar kelas berdasarkan nilai probabilitas yang dihasilkan. Kurva ROC dibentuk dari hubungan antara True Positive Rate (TPR) dan False Positive Rate (FPR), yang masing-masing dihitung menggunakan persamaan:

$$TPR = \frac{TP}{TP + FN} \quad (14)$$


$$FPR = \frac{FP}{FP + TN} \quad (15)$$

Kinerja kurva ROC umumnya diukur menggunakan nilai Area Under Curve (AUC). Nilai AUC berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan kemampuan klasifikasi yang semakin baik. Pada penelitian ini, kurva ROC dan nilai AUC digunakan untuk mengevaluasi performa model Soft Voting yang menghasilkan probabilitas kelas sebagai dasar pengambilan keputusan.

METODE PENELITIAN

Gambar 3 menunjukkan kerangka kerja yang digunakan dalam penelitian ini untuk mengklasifikasikan penyakit daun padi menggunakan ekstraksi fitur berbasis DenseNet201 dan metode Voting Ensemble. Framework yang diusulkan terdiri dari beberapa tahapan utama, yaitu persiapan dataset, preprocessing, pembagian data, augmentasi data, ekstraksi fitur, klasifikasi, ensemble learning, dan evaluasi kinerja model.

Tabel 2 menjelaskan parameter yang digunakan pada masing-masing model klasifikasi. Logistic Regression dijalankan dengan nilai max_iter sebesar 1000 agar proses optimasi dapat berlangsung lebih stabil hingga konvergen. Sementara itu, SVM menggunakan kernel RBF karena kernel ini efektif untuk menangani data berdimensi tinggi dan pola klasifikasi yang tidak linear. Parameter probability pada SVM diaktifkan agar model dapat menghasilkan nilai probabilitas yang diperlukan pada skema soft voting. Selain itu, nilai random_state ditetapkan sebesar 42 untuk menjaga konsistensi hasil eksperimen. Pada metode ensemble, hard voting digunakan untuk menentukan kelas berdasarkan suara mayoritas, sedangkan soft voting menggunakan rata-rata probabilitas dari masing-masing classifier untuk menghasilkan prediksi akhir.



Gambar 3. Kerangka Kerja

Tabel 1. Konfigurasi Eksperimen Penelitian

Komponen	Konfigurasi
Dataset	Paddy Leaf Disease Dataset
Jumlah Kelas	5 kelas
Kelas	Bacterial Leaf Blight, Brown Spot, Healthy Leaf, Leaf Blast, Tungro
Ukuran Citra	224 × 224 piksel
Metode Split Data	Stratified Split
Data Training	80%
Data Validation	10%
Data Testing	10%
Data Augmentation	Rotation, Horizontal Flip, Zoom, Brightness Adjustment
Feature Extractor	DenseNet201 (Pre-trained ImageNet)
Pooling Layer	Global Average Pooling (GAP)
Dimensi Fitur	1920
Base Classifier 1	Logistic Regression
Base Classifier 2	Support Vector Machine (RBF Kernel)
Ensemble Method	Hard Voting, Soft Voting
Metrik Evaluasi	Accuracy, Precision, Recall, F1-Score, Confusion Matrix, ROC-AUC
Format Penyimpanan Model	.pkl

Tabel 2. Parameter Model Klasifikasi

Model	Parameter
Logistic Regression	max_iter = 1000
Logistic Regression	random_state = 42
SVM	kernel = rbf
SVM	probability = True
SVM	random_state = 42
Hard Voting	voting = hard
Soft Voting	voting = soft


Tahap pertama dimulai dengan pengumpulan dataset citra daun padi yang terdiri atas lima kelas, yaitu Bacterial Leaf Blight, Brown Spot, Leaf Blast, Tungro, dan Healthy Leaf. Seluruh citra kemudian melalui tahap preprocessing untuk menyeragamkan kualitas data sebelum digunakan

pada proses pelatihan model. Tahap preprocessing meliputi perubahan ukuran citra (resizing) menjadi 224×224 piksel, normalisasi nilai piksel, serta konversi format warna untuk menyesuaikan kebutuhan arsitektur DenseNet201 (Zhou et al., 2020). Tabel 1 menunjukkan konfigurasi utama yang digunakan dalam penelitian ini.

Setelah proses preprocessing, dataset dibagi menjadi tiga subset menggunakan metode stratified split, yaitu data pelatihan (training set) sebesar 80%, data validasi (validation set) sebesar 10%, dan data pengujian (testing set) sebesar 10%. Pendekatan stratified split digunakan untuk mempertahankan proporsi setiap kelas pada seluruh subset sehingga distribusi data tetap seimbang. Pada tahap pelatihan, dilakukan proses data augmentation untuk meningkatkan variasi data dan mengurangi risiko overfitting. Augmentasi diterapkan hanya pada data pelatihan melalui beberapa transformasi citra, seperti rotasi, pembalikan horizontal (horizontal flip), pembesaran (zoom), dan penyesuaian tingkat kecerahan (brightness adjustment) (Anwar & Zakir, 2021; Shorten & Khoshgoftaar, 2019). Tahap ini bertujuan untuk meningkatkan kemampuan generalisasi model terhadap variasi kondisi citra yang mungkin ditemui pada data baru seperti yang ditampilkan pada gambar 4. Tahap berikutnya adalah ekstraksi fitur menggunakan arsitektur DenseNet201 yang telah dilatih sebelumnya pada dataset ImageNet (pre-trained ImageNet). Pada penelitian ini, DenseNet201 digunakan sebagai feature extractor dengan menghilangkan lapisan klasifikasi bawaan dan mempertahankan bagian konvolusinya. Keluaran dari lapisan konvolusi terakhir kemudian diproses menggunakan Global Average Pooling (GAP) untuk menghasilkan representasi fitur yang lebih ringkas. Proses tersebut menghasilkan vektor fitur berdimensi 1920 yang digunakan sebagai representasi numerik dari setiap citra daun padi.

Vektor fitur hasil ekstraksi selanjutnya digunakan sebagai masukan bagi dua algoritma klasifikasi, yaitu Logistic Regression dan Support Vector Machine (SVM). Kedua algoritma tersebut berperan sebagai base classifier yang secara independen mempelajari pola fitur dan menghasilkan prediksi kelas untuk setiap citra daun padi. Penggunaan dua classifier yang memiliki karakteristik berbeda diharapkan mampu meningkatkan kemampuan model dalam membedakan karakteristik visual antar kelas penyakit.

Untuk memperoleh keputusan klasifikasi yang lebih robust, hasil prediksi dari Logistic Regression dan SVM dikombinasikan menggunakan metode Voting Ensemble. Penelitian ini mengevaluasi dua pendekatan ensemble, yaitu Hard Voting dan Soft Voting. Pada Hard Voting, keputusan akhir ditentukan berdasarkan mayoritas suara dari classifier yang digunakan. Sementara itu, Soft Voting menentukan hasil klasifikasi berdasarkan rata-rata probabilitas yang dihasilkan oleh masing-masing classifier sehingga dapat mempertimbangkan tingkat keyakinan prediksi setiap model.



Gambar 4. Augmentasi data

Tahap terakhir adalah evaluasi kinerja model menggunakan beberapa metrik evaluasi, yaitu Accuracy, Precision, Recall, F1-Score, Confusion Matrix, dan Receiver Operating Characteristic – Area Under Curve (ROC-AUC). Evaluasi dilakukan pada data pengujian untuk mengukur kemampuan model dalam mengklasifikasikan penyakit daun padi secara akurat serta menilai efektivitas metode Voting Ensemble yang diusulkan.

HASIL DAN PEMBAHASAN

Hasil

Dataset dan Hasil Ekstraksi Fitur

Penelitian ini menggunakan dataset Paddy Leaf Disease yang terdiri atas lima kelas, yaitu Bacterial Leaf Blight, Brown Spot, Healthy Leaf, Leaf Blast, dan Tungro. Total dataset yang digunakan berjumlah 1.470 citra dengan distribusi kelas yang relatif seimbang sebagaimana ditunjukkan pada Tabel 3.

Tabel 3. Distribusi Dataset Paddy Leaf Disease

Kelas	Jumlah Citra
Healthy Leaf	333
Brown Spot	307
Leaf Blast	287
Bacterial Leaf Blight	272
Tungro	271
Total	1470


Dataset kemudian dibagi menggunakan metode stratified split dengan proporsi 80% untuk data pelatihan, 10% untuk data validasi, dan 10% untuk data pengujian. Selanjutnya, augmentasi diterapkan hanya pada data pelatihan untuk meningkatkan variasi data dan mengurangi risiko overfitting.

Hasil augmentasi meningkatkan jumlah data pelatihan secara signifikan dari data asli menjadi 7.056 sampel, sedangkan jumlah data validasi dan pengujian masing-masing tetap sebanyak 147 sampel. Setelah proses augmentasi, seluruh citra diekstraksi menggunakan DenseNet201 sehingga menghasilkan representasi fitur berdimensi 1.920 untuk setiap citra.

Tabel 4. Hasil Ekstraksi Fitur DenseNet

Dataset	Jumlah Sampel	Dimensi Fitur
Training	7.056	1.920
Validation	147	1.920
Testing	147	1.920

Hasil tersebut menunjukkan bahwa DenseNet201 berhasil mentransformasikan citra daun padi menjadi representasi numerik berdimensi tinggi yang selanjutnya digunakan sebagai masukan bagi algoritma klasifikasi. sebaran fitur yang dihasilkan disajikan pada gambar 5.



Gambar 5. Visualisasi Distribusi Fitur Hasil Ekstraksi Densenet201 Menggunakan PCA Dua Dimensi.

Hasil Klasifikasi Menggunakan Logistic Regression

Model Logistic Regression dilatih menggunakan fitur hasil ekstraksi DenseNet201. Hasil evaluasi pada data pengujian menunjukkan bahwa model mampu menghasilkan akurasi sebesar 95,24% seperti tersaji pada tabel 5. Model menunjukkan performa yang sangat baik pada kelas Healthy Leaf dengan nilai precision, recall, dan F1-score mencapai 100%. Kesalahan klasifikasi masih ditemukan pada kelas Bacterial Leaf Blight yang memiliki karakteristik visual yang relatif mirip dengan beberapa kelas penyakit lainnya.

Tabel 5. Hasil Klasifikasi Logistic Reression

Kelas	Precision	Recall	F1-Score
Bacterial Leaf Blight	0.8621	0.9259	0.8929
Brown Spot	0.9677	0.9677	0.9677
Healthy Leaf	1.0000	1.0000	1.0000
Leaf Blast	0.9643	0.9310	0.9474
Tungro	0.9615	0.9259	0.9434
Macro Average	0.9511	0.9501	0.9503

Klasifikasi Menggunakan Support Vector Machine

Support Vector Machine (SVM) menghasilkan performa yang lebih baik dibandingkan Logistic Regression. Model memperoleh akurasi sebesar 95,92% dengan nilai F1-score makro sebesar 95,71% seperti tersaji pada tabel 6. Peningkatan performa pada SVM menunjukkan bahwa algoritma ini mampu memanfaatkan fitur berdimensi tinggi yang dihasilkan DenseNet201 secara lebih efektif dibandingkan Logistic Regression.

Tabel 6. Hasil Klasifikasi SVM

Kelas	Precision	Recall	F1-Score
Bacterial Leaf Blight	0.8929	0.9259	0.9091
Brown Spot	0.9677	0.9677	0.9677
Healthy Leaf	1.0000	1.0000	1.0000
Leaf Blast	0.9655	0.9655	0.9655
Tungro	0.9615	0.9259	0.9434
Macro Average	0.9575	0.9570	0.9571

Voting Enseble dengan Hard Voting

Metode Hard Voting menghasilkan akurasi sebesar 95,24%, yang identik dengan performa Logistic Regression seperti tersaji pada tabel 7. Hasil ini menunjukkan bahwa mekanisme voting mayoritas belum mampu meningkatkan performa klasifikasi karena prediksi yang dihasilkan masih sangat dipengaruhi oleh keputusan masing-masing base classifier.

Tabel 7. Hasil Klasifikasi Hard Voting Ensemble

Kelas	Precision	Recall	F1-Score
Bacterial Leaf Blight	0.8621	0.9259	0.8929
Brown Spot	0.9677	0.9677	0.9677
Healthy Leaf	1.0000	1.0000	1.0000
Leaf Blast	0.9643	0.9310	0.9474
Tungro	0.9615	0.9259	0.9434
Macro Average	0.9511	0.9511	0.9511

Voting Ensemble dengan Soft Voting

Soft Voting menghasilkan performa terbaik dengan akurasi sebesar 95,92%, precision sebesar 95,75%, recall sebesar 95,70%, dan F1-score sebesar 95,71% seperti tersaji pada tabel 8. Soft Voting memberikan hasil yang identik dengan SVM karena probabilitas yang dihasilkan SVM memiliki tingkat keyakinan yang lebih dominan dibandingkan Logistic Regression pada sebagian besar sampel pengujian.

Tabel 8. Hasil Klasifikasi Soft Voting Ensemble

Kelas	Precision	Recall	F1-Score
Bacterial Leaf Blight	0.8929	0.9259	0.9091
Brown Spot	0.9677	0.9677	0.9677
Healthy Leaf	1.0000	1.0000	1.0000
Leaf Blast	0.9655	0.9655	0.9655
Tungro	0.9615	0.9259	0.9434
Macro Average	0.9575	0.9570	0.9571

Perbandingan Kinerja Model


Perbandingan performa seluruh model ditunjukkan pada Tabel 9. Berdasarkan hasil tersebut, Soft Voting dan SVM memperoleh performa terbaik dengan akurasi sebesar 95,92%. Nilai ROC-AUC seluruh model probabilistik berada di atas 0,99 yang menunjukkan kemampuan diskriminasi kelas yang sangat baik.

Tabel 9. Perbandingan Kinerja Model

Model	Accuracy (%)	Precision	Recall	F1-Score	ROC-AUC
Logistic Regression	95.24	0.9511	0.9501	0.9503	0.9980
SVM	95.92	0.9575	0.9570	0.9571	0.9976
Hard Voting	95.24	0.9511	0.9501	0.9503	–
Soft Voting	95.92	0.9575	0.9570	0.9571	0.9976

Analisis Confusion Matrix

Untuk memperoleh pemahaman yang lebih mendalam mengenai performa model, dilakukan analisis menggunakan confusion matrix pada seluruh model yang diuji. Confusion matrix memberikan informasi mengenai jumlah prediksi yang benar maupun kesalahan klasifikasi pada setiap kelas penyakit daun padi.



Gambar 6. Confusion Matrix Logistic Regression, SVM, Hard Voting, dan Soft Voting

Berdasarkan Gambar 6, seluruh model menunjukkan dominasi nilai pada diagonal utama matriks yang menandakan sebagian besar sampel berhasil diklasifikasikan dengan benar. Kelas Healthy Leaf menunjukkan performa terbaik pada seluruh model dengan tingkat klasifikasi sempurna, yaitu seluruh 33 sampel berhasil dikenali tanpa kesalahan prediksi.


Hasil ini sejalan dengan nilai precision, recall, dan F1-score yang mencapai 100% pada kelas tersebut. Pada model Logistic Regression dan Hard Voting, terdapat beberapa kesalahan klasifikasi pada kelas Bacterial Leaf Blight. Dari 27 sampel aktual, sebanyak 25 sampel berhasil dikenali dengan benar, sedangkan masing-masing satu sampel salah diklasifikasikan sebagai Leaf Blast dan Tungro. Selain itu, pada kelas Leaf Blast terdapat dua kesalahan prediksi, yaitu satu sampel diklasifikasikan sebagai Bacterial Leaf Blight dan satu sampel sebagai Brown Spot. Kelas Tungro juga menunjukkan dua kesalahan prediksi yang seluruhnya diklasifikasikan sebagai Bacterial Leaf Blight. Pola kesalahan ini mengindikasikan adanya kemiripan karakteristik visual antara beberapa penyakit yang memiliki gejala berupa bercak atau perubahan warna daun.

Model SVM dan Soft Voting menunjukkan peningkatan performa dibandingkan Logistic Regression dan Hard Voting. Pada kelas Leaf Blast, jumlah prediksi benar meningkat dari 27 menjadi 28 sampel sehingga nilai recall kelas tersebut meningkat menjadi 96,55%. Kesalahan klasifikasi pada kelas Leaf Blast hanya tersisa satu sampel yang diprediksi sebagai Brown Spot. Perbaikan ini menunjukkan bahwa SVM lebih mampu membentuk batas pemisah antar kelas pada ruang fitur berdimensi tinggi yang dihasilkan oleh DenseNet201. Jika dianalisis berdasarkan kelas penyakit, kesalahan klasifikasi paling sering terjadi pada kelas Bacterial Leaf Blight, Leaf Blast, dan Tungro. Ketiga penyakit tersebut memiliki gejala visual yang relatif mirip berupa bercak nekrotik, perubahan warna daun, maupun area kerusakan yang menyebar pada permukaan daun. Kondisi ini menyebabkan beberapa sampel berada pada area fitur yang saling berdekatan sehingga meningkatkan kemungkinan terjadinya salah klasifikasi. Sebaliknya, kelas Healthy Leaf dan Brown Spot memiliki karakteristik visual yang lebih mudah dibedakan sehingga menghasilkan tingkat klasifikasi yang sangat tinggi pada seluruh model. Kelas Brown Spot berhasil mencapai 30 prediksi benar dari 31 sampel uji pada seluruh model, sedangkan kelas Healthy Leaf berhasil diklasifikasikan secara sempurna tanpa kesalahan.

Secara keseluruhan, confusion matrix menunjukkan bahwa model SVM dan Soft Voting memiliki distribusi kesalahan yang lebih sedikit dibandingkan Logistic Regression dan Hard Voting. Temuan ini konsisten dengan hasil evaluasi kuantitatif yang menunjukkan bahwa SVM dan Soft Voting memperoleh akurasi tertinggi sebesar 95,92%, sedangkan Logistic Regression dan Hard Voting memperoleh akurasi sebesar 95,24%. Dengan demikian, penggunaan Soft Voting yang menggabungkan probabilitas prediksi dari beberapa classifier mampu menghasilkan keputusan yang lebih stabil dan meningkatkan kemampuan identifikasi penyakit daun padi.

Analisis Receiver Operating Characteristic (ROC) Curve

Selain menggunakan metrik akurasi, precision, recall, dan F1-score, performa model juga dievaluasi menggunakan kurva Receiver Operating Characteristic (ROC). Kurva ROC menggambarkan hubungan antara True Positive Rate (TPR) dan False Positive Rate (FPR) pada berbagai nilai ambang klasifikasi. Semakin dekat kurva ROC terhadap sudut kiri atas, maka semakin baik kemampuan model dalam membedakan antar kelas. Nilai Area Under Curve (AUC) digunakan untuk mengukur kualitas kurva ROC, di mana nilai yang mendekati 1 menunjukkan kemampuan diskriminasi yang sangat baik.



Gambar 7 ROC Curve Logistic Regression, SVM, dan Soft Voting

Berdasarkan Gambar 7 seluruh model menghasilkan kurva ROC yang berada sangat dekat dengan sudut kiri atas grafik. Hal ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan setiap kelas penyakit daun padi. Nilai AUC untuk masing-masing kelas juga berada pada rentang yang sangat tinggi, yaitu di atas 0,99.


Pada model Logistic Regression, nilai AUC untuk setiap kelas berturut-turut adalah 0,9954, 0,9975, 1,0000, 0,9991, dan 0,9981. Nilai AUC sempurna pada kelas Healthy Leaf menunjukkan bahwa model mampu memisahkan kelas daun sehat dari seluruh kelas penyakit tanpa kesalahan diskriminasi. Sementara itu, kelas Bacterial Leaf Blight memperoleh nilai AUC terendah sebesar 0,9954, meskipun nilai tersebut masih termasuk kategori sangat baik.

Model SVM menunjukkan performa yang sedikit lebih stabil dibandingkan Logistic Regression. Nilai AUC yang diperoleh masing-masing kelas adalah 0,9941, 0,9964, 1,0000, 0,9994, dan 0,9981. Meskipun terdapat sedikit penurunan pada kelas Bacterial Leaf Blight dan Brown Spot, peningkatan terjadi pada kelas Leaf Blast, yang memperoleh nilai AUC sebesar 0,9994. Hasil ini menunjukkan bahwa SVM mampu membentuk batas pemisah yang lebih efektif pada ruang fitur berdimensi tinggi hasil ekstraksi DenseNet201.


Model Soft Voting menghasilkan pola ROC yang hampir identik dengan SVM. Nilai AUC yang diperoleh masing-masing kelas adalah 0,9941, 0,9964, 1,0000, 0,9991, dan 0,9985. Nilai tersebut menunjukkan bahwa kombinasi probabilitas dari Logistic Regression dan SVM mampu mempertahankan kemampuan diskriminasi yang sangat tinggi pada seluruh kelas penyakit.

Implementasi Sistem Menggunakan Streamlit

Model terbaik yang diperoleh dari tahap eksperimen kemudian diimplementasikan ke dalam aplikasi berbasis Streamlit untuk memudahkan proses identifikasi penyakit daun padi secara otomatis. Sistem memungkinkan pengguna mengunggah citra daun padi melalui antarmuka web, kemudian sistem melakukan preprocessing, ekstraksi fitur menggunakan DenseNet201, dan klasifikasi menggunakan model Soft Voting.



Gambar 8 Halaman Utama Aplikasi Streamlit



Gambar 9 Hasil Prediksi Penyakit Daun Padi Menggunakan Streamlit

Implementasi ini menunjukkan bahwa model yang dikembangkan tidak hanya memiliki performa yang baik pada lingkungan eksperimen, tetapi juga dapat digunakan sebagai sistem pendukung keputusan untuk membantu proses identifikasi penyakit daun padi secara praktis.

Pembahasan

Hasil penelitian menunjukkan bahwa DenseNet201 mampu berperan secara efektif sebagai feature extractor dengan menghasilkan representasi fitur berdimensi 1.920 yang mampu membedakan karakteristik visual antar kelas penyakit daun padi. Penggunaan transfer learning dari ImageNet memungkinkan model memperoleh fitur yang lebih representatif meskipun jumlah dataset relatif terbatas.

Dari sisi klasifikasi, SVM menunjukkan performa yang lebih baik dibandingkan Logistic Regression. Hal ini mengindikasikan bahwa fitur hasil DenseNet201 memiliki pola yang lebih optimal ketika dipisahkan menggunakan hyperplane nonlinier yang dibentuk oleh kernel SVM. Sementara itu, Soft Voting berhasil mempertahankan performa terbaik dengan memanfaatkan informasi probabilitas dari setiap classifier. Berbeda dengan Hard Voting yang hanya mempertimbangkan suara mayoritas, Soft Voting memperhitungkan tingkat keyakinan prediksi sehingga menghasilkan keputusan yang lebih stabil.

Secara keseluruhan, kombinasi DenseNet201 sebagai feature extractor dan Soft Voting sebagai ensemble classifier terbukti mampu menghasilkan performa klasifikasi yang tinggi dengan akurasi mencapai 95,92% dan ROC-AUC sebesar 0,9976. Hasil tersebut menunjukkan bahwa pendekatan yang diusulkan berpotensi digunakan sebagai solusi otomatis untuk mendukung deteksi dini penyakit daun padi pada lingkungan pertanian.

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa arsitektur DenseNet201 berhasil digunakan sebagai feature extractor untuk mengubah citra daun padi menjadi representasi fitur numerik berdimensi 1.920 yang mampu merepresentasikan karakteristik visual setiap kelas penyakit dengan baik. Dataset yang digunakan terdiri atas 1.470 citra daun padi yang terbagi ke dalam lima kelas, yaitu Bacterial Leaf Blight, Brown Spot, Healthy Leaf, Leaf Blast, dan Tungro. Penerapan teknik augmentasi pada data pelatihan berhasil meningkatkan jumlah sampel pelatihan menjadi 7.056 data, sehingga memperkaya variasi data dan membantu meningkatkan kemampuan generalisasi model.

Hasil pengujian menunjukkan bahwa seluruh model klasifikasi yang digunakan mampu memberikan performa yang sangat baik dalam mengidentifikasi penyakit daun padi. Logistic

Regression menghasilkan akurasi sebesar 95,24% dengan nilai precision, recall, dan F1-score masing-masing sebesar 95,11%, 95,01%, dan 95,03%. Sementara itu, Support Vector Machine (SVM) memperoleh performa terbaik dengan akurasi sebesar 95,92%, precision sebesar 95,75%, recall sebesar 95,70%, dan F1-score sebesar 95,71%. Pada metode Voting Ensemble, Hard Voting menghasilkan performa yang sama dengan Logistic Regression, sedangkan Soft Voting mampu mencapai performa yang setara dengan SVM dengan akurasi sebesar 95,92% dan nilai F1-score sebesar 95,71%.

Analisis confusion matrix menunjukkan bahwa sebagian besar sampel berhasil diklasifikasikan dengan benar pada seluruh kelas. Kelas Healthy Leaf menjadi kelas dengan performa terbaik karena seluruh sampel berhasil dikenali tanpa kesalahan klasifikasi. Kesalahan prediksi yang masih terjadi umumnya ditemukan pada kelas Bacterial Leaf Blight, Leaf Blast, dan Tungro yang memiliki karakteristik visual yang relatif mirip. Hasil evaluasi menggunakan ROC Curve juga menunjukkan kemampuan diskriminasi yang sangat tinggi pada seluruh model dengan nilai ROC-AUC di atas 0,99. Temuan ini menunjukkan bahwa fitur yang dihasilkan DenseNet201 mampu memisahkan setiap kelas penyakit dengan sangat baik.

Selain itu, model terbaik berhasil diimplementasikan ke dalam aplikasi berbasis Streamlit yang memungkinkan pengguna melakukan identifikasi penyakit daun padi secara otomatis melalui unggahan citra daun. Implementasi ini membuktikan bahwa kombinasi DenseNet201 sebagai ekstraktor fitur dan metode Soft Voting sebagai classifier mampu menghasilkan sistem identifikasi penyakit daun padi yang akurat, efisien, dan berpotensi untuk diterapkan sebagai alat bantu deteksi dini penyakit pada sektor pertanian.

Saran

Berdasarkan hasil penelitian yang telah diperoleh, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya. Penggunaan dataset dengan jumlah yang lebih besar dan kondisi citra yang lebih beragam perlu dilakukan untuk meningkatkan kemampuan generalisasi model terhadap berbagai kondisi lapangan. Selain itu, penelitian berikutnya dapat membandingkan performa DenseNet201 dengan arsitektur ekstraksi fitur lainnya, seperti EfficientNet, ConvNeXt, ResNet, maupun Vision Transformer untuk memperoleh representasi fitur yang lebih optimal.

Pengembangan metode klasifikasi juga dapat dilakukan dengan menambahkan classifier lain seperti Random Forest, XGBoost, LightGBM, atau Broad Learning System (BLS) ke dalam skema ensemble sehingga diperoleh kombinasi model yang lebih kuat. Optimasi hyperparameter pada Logistic Regression, SVM, maupun metode Voting Ensemble juga dapat dilakukan untuk meningkatkan performa klasifikasi. Dari sisi implementasi, aplikasi yang telah dikembangkan dapat diperluas menjadi aplikasi berbasis perangkat bergerak atau layanan berbasis cloud sehingga dapat digunakan secara langsung oleh petani dan penyuluh pertanian di lapangan. Selain melakukan identifikasi penyakit, penelitian selanjutnya juga dapat menambahkan fitur rekomendasi penanganan penyakit secara otomatis sehingga sistem yang dikembangkan tidak hanya mampu mendeteksi penyakit, tetapi juga mendukung pengambilan keputusan dalam pengelolaan tanaman padi secara lebih efektif.

DAFTAR PUSTAKA

Eko Fuji Pangestu, & Bambang Irawan. (2026). KLASIFIKASI PENYAKIT TANAMAN PADI MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR MOBILNETV2. Jurnal Informatika Dan Teknik Elektro Terapan, 14(1).
<https://doi.org/10.23960/jitet.v14i1.8900>

- Adiana, A. T., Jumadi, J., & Nurlatifah, E. (2025). Klasifikasi Penyakit Pada Daun Padi Menggunakan Model Hybrid CNN-SVM. *SMATIKA JURNAL*, 15(02), 258-267. <https://doi.org/10.32664/smatika.v15i02.1548>
- Adnan, I. I., Waughfa, M. Z., & Joyee, M. A. (2024). Utilizing Squeeze-and-Excite Mechanisms and Voting Ensembles Technique for Coffee Leaf Disease Detection. 2024 2nd International Conference on Information and Communication Technology (ICICT), 194-198. <https://doi.org/10.1109/ICICT64387.2024.10839718>
- Albawi, S., Mohammed, T. A. M., & Alzawi, S. (2017). Understanding of a Convolutional Neural Network. *Icet2017*, 1-6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Albelwi, S. A. (2022). Deep Architecture based on DenseNet-121 Model for Weather Image Recognition. *International Journal of Advanced Computer Science and Applications*, 13(10), 559-565. <https://doi.org/10.14569/IJACSA.2022.0131065>
- Anup Chandra Mondal. (2024). Paddy Leaf Disease. In *Mendeley Data* (Vol. V1). doi: 10.17632/fys884zvyr.1
- Anwar, T., & Zakir, S. (2021). Effect of Image Augmentation on ECG Image Classification using Deep Learning. 2021 International Conference on Artificial Intelligence, ICAI 2021, 182-186. <https://doi.org/10.1109/ICAI52203.2021.9445258>
- Bhutia, T. P., Rao, Y. D., Kharel, P., Rai, P., Rana, M., & Srivastava, S. (2025). A comprehensive review on brown spot disease of rice: etiology, epidemiology, management strategies and future directions. *Plant Science Today*. <https://doi.org/10.14719/pst.4657>
- Bin Habib, A. Z. S., & Tasnim, T. (2020). An Ensemble Hard Voting Model for Cardiovascular Disease Prediction. 2020 2nd International Conference on Sustainable Technologies for Industry 4.0, STI 2020, 0, 19-20. <https://doi.org/10.1109/STI50764.2020.9350514>
- Chintyana, A., Hastuti, S. H., Khotimah, H., Chintyana, A., Hastuti, S. H., & Khotimah, H. (2024). Support Vector Machine-Radial Basis Function Kernel and K-Nearest Neighbor Differences for Classification Superior Varieties of Rice in Indonesia. *Euler : Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 12(2). <https://doi.org/10.37905/euler.v12i2.27605>
- Dey, D., Haque, Md. S., Islam, Md. M., Aishi, U. I., Shammy, S. S., Mayen, Md. S. A., Noor, S. T. A., & Uddin, Md. J. (2025). The proper application of logistic regression model in complex survey data: a systematic review. *BMC Medical Research Methodology*, 25(1), 15. <https://doi.org/10.1186/s12874-024-02454-5>
- Joly, N. A., Munchi, R., Mohalder, R. D., Reya, F. M., Islam, M. S., & Chowdhury, S. (2025). A Majority Hard Voting Based Ensemble Approach to Predict Cardiovascular Disease. 2025 International Conference on Electrical, Computer and Communication Engineering (ECCE), 1-6. <https://doi.org/10.1109/ECCE64574.2025.11013017>
- Khoiruddin, M., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network. *Journal of Dinda : Data Science, Information Technology, and Data Analytics*, 2(1), 37-45. <https://doi.org/10.20895/dinda.v2i1.341>
- Kurniawan, R., Samsuryadi, Mohamad, F. S., Wijaya, H. O. L., & Santoso, B. (2025a). Advancing palm oil fruit ripeness classification using transfer learning in deep neural networks. *Bulletin of Electrical Engineering and Informatics*, 14(2), 1126-1137. <https://doi.org/10.11591/eei.v14i2.8651>

- Kurniawan, R., Samsuryadi, Mohamad, F. S., Wijaya, H. O. L., & Santoso, B. (2025b). Classification of palm oil fruit ripeness based on AlexNet deep Convolutional Neural Network. *Sinergi (Indonesia)*, 29(1), 207–220. <https://doi.org/10.22441/sinergi.2025.1.019>
- Kurniawan, R., Siaga, E., Samsuryadi, S., Susilo, A. T., & Sunardi, L. (2025). Hybrid DCNN-SVM Architecture for Optimizing Sugarcane Leaf Disease Classification. *IAENG International Journal of Computer Science*, 52(4), 974–985.
- Kusuma, B., Hermanto, T. I., & Lestari, C. D. (2025). KLASIFIKASI JENIS PENYAKIT PADA TANAMAN PADI MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK. *JIKO (Jurnal Informatika Dan Komputer)*, 9(1), 40. <https://doi.org/10.26798/jiko.v9i1.1395>
- Mallick, T., Banerjee, S., Thakur, N., Saha, H. N., & Chakrabarti, A. (2025). Evaluation of State-of-the-Art Deep Learning Techniques for Plant Disease and Pest Detection. *Computer, Materials & Continua*. <https://doi.org/10.32604/cmc.2025.065250>
- Maulana, M. F. A., Anggadimas, N. M., & Sani, D. A. (2025). Klasifikasi Citra Penyakit Daun Padi Dengan Metode CNN Menggunakan Arsitektur ResNet50V2. *CESS (Journal of Computer Engineering, System and Science)*, 10(2), 517–529. <https://doi.org/10.24114/cess.v10i2.66960>
- Milano, A. C. (2024). KLASIFIKASI PENYAKIT DAUN PADI MENGGUNAKAN MODEL DEEP LEARNING EFFICIENTNET-B6. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(1). <https://doi.org/10.23960/jitet.v12i1.3855>
- Moh. Heri Susanto, Irwan Budi Santoso, Suhartono, & Ahmad Fahmi Karami. (2025). Klasifikasi Penyakit Padi Menggunakan Convolutional Neural Network (CNN) Berbasis Citra Daun. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 14(3), 181–189. <https://doi.org/10.22146/jnteti.v14i3.18791>
- Morgan-Benita, J. A., Galván-Tejada, C. E., Cruz, M., Galván-Tejada, J. I., Gamboa-Rosales, H., Arceo-Olague, J. G., Luna-García, H., & Celaya-Padilla, J. M. (2022). Hard Voting Ensemble Approach for the Detection of Type 2 Diabetes in Mexican Population with Non-Glucose Related Features. *Healthcare (Switzerland)*, 10(8). <https://doi.org/10.3390/healthcare10081362>
- O'Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. *ArXiv:1511.08458v2*, (December). <http://arxiv.org/abs/1511.08458>
- Pangga, I. B., & Sta. Cruz, F. C. (2024). Rice tungro disease. In *Viral Diseases of Field and Horticultural Crops* (pp. 81–86). Elsevier. <https://doi.org/10.1016/B978-0-323-90899-3.00071-9>
- Putra Pranjaya, A., Rizki, F., Kurniawan, R., & Daulay, N. K. (2024). Klasifikasi Penyakit Pada Daun Tanaman Padi Berbasis YoloV5 (You Only Look Once). *Media Online*, 4(6), 3127–3136. <https://doi.org/10.30865/klik.v4i6.1916>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Ulfi, M., Supriyanto, M. I. A., Sari, C. M., & Nuswantoro, S. A. (2025). Identifikasi Penyakit pada Tanaman Padi Menggunakan Convolutional Neural Network (CNN). *Jurnal Sains Komputer Dan Teknologi Informasi*, 7(2), 89–96. <https://doi.org/10.33084/jsakti.v7i2.10061>
- Vengaiah, C., & Konda, S. R. (2023). Improving Tomato Leaf Disease Detection with DenseNet-121 Architecture. *INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING*, 11(3), 442–448.
- Xu, J., Zhang, Y., & Miao, D. (2020). Three-way confusion matrix for classification: A measure driven view. *Information Sciences*, 507, 772–794. <https://doi.org/10.1016/j.ins.2019.06.064>

- Zhang, G., Xu, T., Tian, Y., Feng, S., Zhao, D., & Guo, Z. (2022). Classification of rice leaf blast severity using hyperspectral imaging. *Scientific Reports*, 12(1), 19757. <https://doi.org/10.1038/s41598-022-22074-7>
- Zhou, W., Ma, X., & Zhang, Y. (2020). Research on Image Preprocessing Algorithm and Deep Learning of Iris Recognition. *Journal of Physics: Conference Series*, 1621(1), 012008. <https://doi.org/10.1088/1742-6596/1621/1/012008>