

Klasifikasi Penyakit Pada Daun Padi Menggunakan Model Hybrid CNN-SVM

Agus Tri Adiana^{1*}
Jumadi²
Eva Nurlatifah³

^{1,2,3}Teknik Informatika, Fakultas Sains dan Teknologi, UIN Sunan Gunung Djati Bandung
Jl. AH. Nasution No.105, Cipadung Wetan, Kec. Cibiru, Kota Bandung, Jawa Barat 40614,
Indonesia

¹agusstri43@gmail.com, ²jumadi@uinsgd.ac.id, ³evanurlatifah@uinsgd.ac.id

Penulis Korespondensi:

Agus Tri Adiana
agusstri43@gmail.com

Abstrak

Produksi padi di Indonesia menghadapi tantangan serius akibat berkurangnya luas lahan pertanian dan serangan penyakit seperti Bacterial Leaf Blight, Blast, dan Brown Spot, yang dapat menurunkan hasil panen hingga 80% dan mengancam ketahanan pangan nasional. Penyakit tersebut tidak hanya merusak stabilitas produksi tetapi juga menyebabkan kerugian yang signifikan bagi petani. Identifikasi dini penting untuk mencegah kerugian, namun keterbatasan pengetahuan petani sering menyebabkan kesalahan diagnosis dan penanganan. Untuk mengatasi masalah ini, penelitian ini mengusulkan pengembangan model klasifikasi penyakit daun padi berbasis hybrid Convolutional Neural Network (CNN) dan Support Vector Machine (SVM), yang dirancang menggunakan metode CRISP-DM (Cross-Industry Standard Process for Data Mining) dari tahap business understanding hingga evaluation. Dengan dataset berisi 11.790 gambar daun padi dari sembilan kelas penyakit. CNN menggunakan arsitektur VGG-16 yang dipakai untuk ekstraksi fitur, sedangkan SVM menangani klasifikasi multi-kelas dengan metode one-vs-rest. Hasil evaluasi menunjukkan akurasi model sebesar 95%, dengan precision, recall, dan F1-score yang tinggi di sebagian besar kelas penyakit. Hasil tersebut menunjukkan potensi yang signifikan dan diharapkan dapat membantu petani untuk melakukan deteksi dini penyakit pada padi.

Kata Kunci: CNN; Klasifikasi Gambar; Model Hybrid; Penyakit Padi; SVM.

Abstract

Rice production in Indonesia faces significant challenges due to the declining area of agricultural land and the prevalence of diseases such as Bacterial Leaf Blight, Blast, and Brown Spot, which can reduce yields by up to 80% and threaten national food security. These diseases not only disrupt production stability but also cause substantial losses for farmers. Early identification is crucial to prevent such losses; however, farmers often struggle with limited knowledge, leading to misdiagnosis and improper management. To address this issue, this study proposes the development of a hybrid disease classification model for rice leaves based on Convolutional Neural Network (CNN) and Support Vector Machine (SVM). The model is designed following the CRISP-DM (Cross-Industry Standard Process for Data Mining) methodology, encompassing stages from business understanding to evaluation. Using a dataset containing 11,790 images of rice leaves from nine disease classes, the VGG-16 architecture is utilized for feature extraction, while SVM handles multi-class classification through the one-vs-rest approach. Evaluation results demonstrate a model accuracy of 95%, with high precision, recall, and F1-scores across most disease classes. These findings highlight the model's significant potential to aid farmers in the early detection of rice diseases.

Keywords: CNN; Hybrid Model; Image Classification; Rice Disease; SVM

1. Pendahuluan

Padi (*Oryza sativa*) adalah tanaman pangan yang menjadi sumber utama bagi masyarakat Indonesia terutama sebagai komoditas hasil pertanian berupa beras. Selain itu, padi memegang peran yang penting dalam mempertahankan stabilitas dan ketahanan pangan nasional [1]. Seiring dengan meningkatnya jumlah penduduk, permintaan beras sebagai kebutuhan pokok bagi masyarakat pun akan meningkat tiap tahunnya. Karena itu, hasil panen yang stabil menjadi salah

satu aspek yang krusial. Sayangnya, menurut data Badan Pusat Statistik (BPS), Produksi padi dan beras mengalami penurunan pada tahun 2024 jika dibandingkan dengan tahun 2023.. Produksi padi menurun sebanyak 1,32 juta ton dan produksi beras menurun sebesar 757,13 ribu ton. Selain itu, luas panen padi pun juga menyusut hingga 167,25 ribu hektare [2].

Selain penurunan luas lahan, serangan hama dan penyakit juga menjadi faktor signifikan yang berkontribusi terhadap penurunan produksi padi dan beras. Beberapa penyakit utama yang berdampak serius pada produksi padi mencakup *Bacterial blight*, *Blast*, *Brown Spot*, dan *Tungro* [3]. *Bacterial blight* merupakan salah satu penyakit paling merusak yang diakibatkan oleh serangan bakteri *Xanthomonas oryzae pv. oryzae* (Xoo), dan dapat mengurangi produksi sebesar 15-80% tergantung pada tahap pertumbuhan tanaman saat terinfeksi [4]. Serangan penyakit pada tanaman padi dapat membuat petani kehilangan hasil panen hingga 300.000 ton per tahun [5]. Penyakit-penyakit yang ada pada tanaman padi biasanya menyerang daun padi [6]. Tanaman padi yang terinfeksi penyakit menunjukkan gejala seperti perubahan warna dan munculnya pola tertentu pada daun. Gejala yang muncul pada daun dapat digunakan sebagai langkah awal untuk mengetahui jenis penyakit yang menyerang tanaman padi.[7]. Penyakit pada tanaman padi sebenarnya bisa dilihat secara langsung melalui pengamatan visual, namun akibat keterbatasan pengetahuan dan wawasan petani sering kali terjadi kesalahan yang mengakibatkan kesalahan dalam penanganan [8]. Hal ini dapat menyebabkan kerugian bagi petani, termasuk risiko gagal panen.

Kemajuan teknologi saat ini memungkinkan identifikasi penyakit padi menggunakan kecerdasan buatan, terutama melalui metode *Deep Learning*, yang dianggap lebih unggul daripada teknik *Machine Learning* lainnya [9], [10]. Dalam klasifikasi citra, *Convolutional Neural Network* (CNN) populer karena akurasi tinggi dalam pemrosesan gambar melalui lapisan konvolusionalnya, yang bekerja seperti respons neuron terhadap stimulus [11], [12]. Selain CNN, *Support Vector Machine* (SVM) juga sering digunakan dalam klasifikasi karena kemampuannya menangani data linear dan non-linear pada masalah klasifikasi maupun regresi [13]. SVM awalnya dikembangkan untuk klasifikasi dua kelas dan kemudian diperluas untuk klasifikasi multi-kelas, salah satu pendekatan yang biasanya digunakan dalam klasifikasi multi-kelas pada SVM adalah *one-vs-rest* [14]. Metode SVM menggunakan tiga jenis kernel utama, yaitu radial, linear, dan sigmoid [15]. Penggunaan teknologi ini tentu dapat membantu proses identifikasi penyakit padi dengan lebih tepat, sekaligus mengurangi kesalahan dalam identifikasi secara langsung.

Penelitian sebelumnya telah mengkaji klasifikasi penyakit pada tanaman dengan menggunakan metode *Deep Learning* dan *Machine Learning*. Penggunaan CNN dengan arsitektur MobileNetV1 dan teknik *Feature Extraction* dalam deteksi penyakit pada daun padi mencapai akurasi 92%, tetapi penelitian ini terbatas oleh ukuran dataset yang kecil sehingga rentan terhadap *overfitting* [16]. Selanjutnya Penggunaan *Support Vector Machine* (SVM) dengan kombinasi fitur tekstur dan warna untuk klasifikasi penyakit daun jagung, mencapai akurasi 99,5% [17]. Sementara itu, penelitian menggunakan model hybrid CNN-SVM untuk klasifikasi kesegaran daging ayam, mencapai akurasi 95%, namun model terhambat oleh distribusi dataset yang tidak merata yang menyebabkan proses pelatihan dan pengujian tidak maksimal [18]. Penelitian lainnya yang menggunakan hybrid model yaitu implementasi algoritma VGG-16 dengan Support Vector Machine untuk melakukan klasifikasi jenis buah dan sayuran mendapatkan akurasi sebesar 91,76%[19].

Dataset daun padi sering menghadirkan tantangan visual yang kompleks, seperti variasi intensitas warna, pola gejala penyakit yang tidak konsisten, serta keberadaan noise atau gangguan dari latar belakang gambar yang dapat mengaburkan informasi penting. Penelitian ini mengusulkan penerapan model hybrid CNN-SVM untuk mengatasi tantangan tersebut sekaligus memperbaiki keterbatasan model sebelumnya. Pendekatan ini memadukan keunggulan CNN dalam mengekstraksi fitur visual yang mendalam dan kompleks dengan keandalan SVM dalam

menangani data non-linear, menjadikannya lebih efektif untuk klasifikasi penyakit daun padi. Berbeda dengan metode tunggal seperti CNN MobileNetV1 yang rentan terhadap *overfitting* akibat keterbatasan dataset [16], atau SVM yang mengandalkan fitur tekstur dan warna yang kurang optimal pada dataset dengan karakteristik beragam [17], model *hybrid* CNN-SVM dirancang untuk menghasilkan klasifikasi yang lebih stabil dan akurat. Meskipun kombinasi CNN-SVM telah diterapkan di domain lain, studi dalam domain pertanian, khususnya untuk klasifikasi penyakit pada daun padi, masih jarang dilakukan. Penelitian ini bertujuan mengisi gap tersebut dengan menawarkan solusi inovatif yang mampu mengatasi masalah *overfitting* dan ketidakseimbangan distribusi data, sehingga memberikan kontribusi signifikan terhadap pengembangan teknologi deteksi penyakit tanaman.

2. Metode Penelitian


Penelitian ini mengaplikasikan metode CRISP-DM (*Cross-Industry Standard Process for Data Mining*). CRISP-DM adalah pendekatan sistematis yang dirancang khusus untuk melakukan untuk melakukan perancangan dan pelatihan model serta proses data mining secara terstruktur dan efektif yang terdiri dari 6 tahap [20]. Dalam penelitian ini, tahapan yang diterapkan mencakup seluruh proses CRISP-DM hingga tahap evaluasi, sementara tahap *deployment* tidak diterapkan dalam penelitian ini.

Business Understanding

Penelitian ini berfokus pada pembuatan model klasifikasi jenis penyakit daun padi yang diharapkan dapat membantu mengidentifikasi penyakit secara efektif dan akurat. Serangan penyakit pada tanaman padi yang dapat menurunkan hasil panen secara signifikan, menjadi tantangan besar bagi petani dan berpotensi menimbulkan kerugian ekonomi. Dari hal tersebut, tujuan dilakukannya penelitian ini adalah menemukan solusi untuk deteksi dini penyakit daun padi agar pengendalian dapat dilakukan tepat waktu, sehingga mengurangi risiko gagal panen. Dengan mengusulkan model hybrid CNN-SVM, yang mengombinasikan kemampuan CNN dalam mengekstraksi fitur visual dengan keandalan SVM dalam mengklasifikasikan data non-linear, penelitian ini diharapkan dapat meningkatkan akurasi identifikasi serta mengatasi risiko *overfitting*.

Data Understanding

Penelitian ini menggunakan dataset dari Kaggle yang dipublikasikan oleh pengguna Yuji Itadori [21]. Dataset memiliki total 11.790 gambar daun padi yang terbagi ke dalam sembilan kelas: *Bacterial Leaf Blight* (1.197 gambar), *Brown Spot* (1.546 gambar), *Healthy Rice Leaf* (1.085 gambar), *Leaf Blast* (1.748 gambar), *Leaf Scald* (1.332 gambar), *Narrow Brown Leaf Spot* (954 gambar), *Neck Blast* (1.000 gambar), *Rice Hispa* (1.299 gambar), dan *Sheath Blight* (1.629 gambar). Setiap kelas mencakup pola visual spesifik yang penting dalam proses ekstraksi fitur dan klasifikasi penyakit pada daun padi. Gambar berikut menunjukkan distribusi jumlah data pada setiap kelas.



Gambar 1. Distribusi data tiap kelas**Data Preparation**

Pada tahap *Data Preparation*, dataset diolah agar siap digunakan dalam model klasifikasi. Untuk meningkatkan variasi dalam dataset, dilakukan augmentasi data secara manual karena distribusi data setiap kelas tidak merata. Augmentasi ini mencakup *rotation*, di mana gambar diputar dengan sudut tertentu untuk mensimulasikan variasi orientasi daun, *scaling*, yang mengubah ukuran gambar untuk merepresentasikan perbedaan ukuran daun, *flipping*, yaitu mencerminkan gambar secara horizontal atau vertikal untuk menambah variasi orientasi, serta *color manipulation*, seperti penyesuaian warna, kecerahan, atau kontras untuk mensimulasikan perubahan kondisi pencahayaan. Setelah augmentasi selanjutnya gambar daun padi diubah ke ukuran seragam 224x224 piksel, sementara nilai pikselnya dinormalisasi ke rentang 0 hingga 1 untuk mempercepat konvergensi dan menjaga stabilitas selama pelatihan. Dataset kemudian dibagi menjadi dua bagian: training dan test. 80% data dialokasikan untuk training dan 20% dialokasikan untuk test untuk mengevaluasi secara objektif kinerja model. Karena model menggunakan pendekatan hybrid CNN-SVM, label diubah dari format *one-hot encoding* ke format numerik biasa agar sesuai dengan input yang diharapkan oleh SVM, memastikan seluruh data siap untuk proses pelatihan dan pengujian model secara efektif.

Modeling

Pada tahap *modeling*, penelitian ini menerapkan pendekatan *hybrid* antara *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM) untuk mengklasifikasikan penyakit daun padi. Dalam penelitian ini, CNN bertanggung jawab dalam proses *feature learning*, yang mencakup identifikasi pola spesifik pada gambar daun yang terinfeksi penyakit. VGG-16 dipilih sebagai arsitektur CNN karena strukturnya yang mendalam namun efisien dalam mendeteksi pola visual pada gambar daun padi beresolusi tinggi, sehingga diharapkan mampu memaksimalkan proses ekstraksi fitur.


Hasil ekstraksi fitur melalui VGG-16 kemudian diklasifikasikan menggunakan SVM. Karena dataset yang digunakan merupakan multi-class, pendekatan *one-vs-rest* diterapkan pada SVM untuk menangani klasifikasi. Metode *one-vs-rest* dipilih karena memungkinkan setiap kelas penyakit diuji terhadap gabungan semua kelas lain sebagai satu kategori, sehingga meningkatkan keakuratan klasifikasi dalam kondisi multi-class dan membantu mengatasi potensi kesalahan klasifikasi. Pada penelitian ini, digunakan kernel linear pada SVM karena lebih efisien dalam komputasi, terutama pada dataset dengan dimensi fitur tinggi yang dihasilkan oleh VGG-16. Kernel linear juga dipilih karena distribusi fitur yang dihasilkan dari ekstraksi CNN sudah cukup representatif, sehingga data antar kelas dapat dipisahkan secara linear tanpa perlu pemetaan ke ruang dimensi yang lebih tinggi seperti yang dilakukan oleh kernel non-linear (misalnya RBF). Selain itu, kernel linear memiliki risiko *overfitting* yang lebih rendah dibandingkan kernel non-linear, menjadikannya pilihan yang lebih stabil untuk dataset ini.

Evaluation

Pada tahap evaluasi model, dilakukan pengukuran kinerja model hybrid CNN-SVM dalam mengklasifikasikan penyakit daun padi menggunakan empat metrik utama: *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik tersebut dipilih untuk memberikan gambaran menyeluruh terkait performa model, baik secara keseluruhan maupun pada setiap kelas penyakit secara spesifik. Masing-masing metrik ini memberikan pandangan yang spesifik tentang kinerja model dalam berbagai aspek, terutama dalam menangani ketepatan dan kelengkapan klasifikasi untuk setiap kelas penyakit. Penggunaan keempat metrik ini memberikan evaluasi yang lebih mendalam terhadap performa model, memastikan bahwa model tidak hanya baik secara keseluruhan (melalui akurasi) tetapi juga andal dalam hal ketepatan, sensitivitas, dan keseimbangan dalam klasifikasi pada tiap kelas penyakit.

3. Hasil


Evaluasi hasil kinerja model dilakukan menggunakan confusion matrix yang ditunjukkan pada gambar 2. Gambar tersebut memvisualisasikan hasil klasifikasi penyakit daun padi pada data uji. Confusion matrix memberikan informasi rinci tentang prediksi benar dan salah untuk masing-masing kelas, yaitu *Bacterial Leaf Blight*, *Brown Spot*, *Healthy Rice Leaf*, *Leaf Blast*, *Leaf Scald*, *Narrow Brown Leaf Spot*, *Neck Blast*, *Rice Hispa*, dan *Sheath Blight*. Dengan visualisasi ini, kita dapat menilai tingkat akurasi model dalam mengenali setiap kelas penyakit secara spesifik dan mengidentifikasi kelas yang memiliki tingkat kesalahan prediksi tinggi.



Gambar 2. Confusion Matrix

Berdasarkan *confusion matrix* pada Gambar 2, Model menunjukkan performa yang sangat baik dalam melakukan klasifikasi berbagai jenis penyakit pada daun padi. Kelas *Brown Spot* dan *Sheath Blight* memiliki jumlah prediksi benar yang sangat tinggi, masing-masing sebanyak 300 dan 323 sampel, yang menunjukkan kemampuan model dalam mengenali kedua kelas ini dengan akurasi yang tinggi. Kelas *Leaf Blast* dan *Rice Hispa* juga menunjukkan performa yang baik, dengan masing-masing 342 dan 242 sampel yang diklasifikasikan dengan benar.

Selain *confusion matrix*, performa model dalam mengklasifikasikan penyakit pada daun padi juga dapat dilihat melalui *classification report* yang divisualisasikan dalam bentuk *heatmap* pada Gambar 3. *Heatmap* ini menampilkan metrik *precision*, *recall*, dan *f1-score* untuk masing-masing kelas, yang memberikan penilaian lebih rinci terhadap kemampuan model dalam mengidentifikasi setiap kategori penyakit.



Gambar 3. Classification Report Heatmap

Dari *classification report heatmap* di atas, dapat dilihat bahwa model memiliki performa yang baik, ditunjukkan oleh nilai *precision*, *recall*, dan *f1-score* yang tinggi di hampir semua kelas penyakit daun padi. Metrik ini sangat penting dalam mengevaluasi seberapa efektif model dalam membedakan tiap kelas penyakit secara akurat. Sebagai contoh, pada kelas *Leaf Blast*, model menunjukkan hasil evaluasi yang sangat baik dengan nilai *precision* sebesar 0.94, *recall* sebesar 0.96, dan *f1-score* sebesar 0.95. Berikut adalah penjelasan dari perhitungan untuk metrik tersebut:

Berdasarkan confusion matrix pada gambar 2 dapat diketahui *true positives* (TP) untuk *Leaf Blast* adalah 342, *false positives* (FP) untuk *Leaf Blast* adalah 21, dan *false negatives* (FN) untuk *Leaf Blast* adalah 15. Berdasarkan nilai TP, FP, dan FN yang sudah disebutkan perhitungan metrik untuk kelas *Leaf Blast* sebagai berikut :

$$Precision = \frac{TP}{TP+FP} = \frac{342}{342+21} = \frac{342}{363} \approx 0,94 \quad (1)$$

$$Recall = \frac{TP}{TP+FN} = \frac{342}{342+15} = \frac{342}{357} \approx 0,96 \quad (2)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} = 2 \times \frac{0,94 \times 0,96}{0,94+0,96} = 2 \times \frac{0,902}{1,9} \approx 0,95 \quad (3)$$

Berdasarkan perhitungan di atas, didapatkan bahwa untuk kelas *Leaf Blast*, nilai *precision* yang diperoleh dari Persamaan (1) adalah 0,94. Selanjutnya, nilai *recall* yang dihitung dengan Persamaan (2) menghasilkan 0,96. Terakhir, nilai *F1-score* dihitung dengan Persamaan (3) menghasilkan 0,95. Nilai-nilai metrik ini sesuai dengan yang ditampilkan pada *classification report heatmap*. Perhitungan yang sama juga berlaku untuk kelas-kelas lain, sehingga nilai *precision*, *recall*, dan *F1-score* untuk setiap kelas dalam *classification report heatmap* sudah sesuai. Hasil ini menunjukkan bahwa model memiliki performa yang baik dalam mengenali kelas penyakit *Leaf Blast*.

Pada tabel 1 di bawah ini menyajikan hasil evaluasi model secara komprehensif. Hasil evaluasi mencakup nilai akurasi pada data *train* dan *test*, yang memberikan gambaran umum mengenai performa model dalam membedakan antara data yang telah dilatih dan data yang baru. Selain itu, ditampilkan pula metrik evaluasi lainnya, yaitu *precision*, *recall*, dan *F1-Score* untuk setiap kelas, yang memungkinkan analisis lebih mendalam terkait keakuratan model dalam mengklasifikasikan masing-masing kategori.

Tabel 1. Hasil Evaluasi Model

	Precision	Recall	F1-Score
Bacterial Leaf Blight	0.93	0.93	0.93
Brown Spot	0.93	0.96	0.94
Healthy Rice Leaf	0.96	0.97	0.97
Leaf Blast	0.94	0.96	0.95
Leaf Scald	0.95	0.95	0.95
Narrow Brown Leaf Spot	0.97	0.84	0.90
Neck Blast	1.00	1.00	1.00
Rice Hispa	0.96	0.97	0.97
Sheath Blight	0.96	0.97	0.97
Accuracy			0,95
Macro Avg	0.95	0.95	0.95
Weighted Avg	0.95	0.95	0.95

Berdasarkan hasil yang ditampilkan pada Tabel 1 model menunjukkan performa yang sangat baik dengan nilai akurasi 95% pada data test. Ini berarti bahwa model mampu mengklasifikasikan 95% sampel data test dengan benar, Menunjukkan bahwa model memiliki kemampuan yang baik dalam menggeneralisasi data yang belum pernah dilihat sebelumnya. Untuk nilai akurasi tersebut diperoleh dari perhitungan berikut :

$$Accuracy = \frac{\text{Number of Correct Prediction}}{\text{Total Number of Prediction}} = \frac{2245}{2358} \approx 0,95 \quad (4)$$

Sebagai perbandingan, penelitian sebelumnya yang menerapkan arsitektur MobileNetV1 dengan teknik *Feature Extraction* [16] memperoleh akurasi sebesar 92%. Meskipun hasil tersebut cukup baik, penelitian tersebut menggunakan dataset yang lebih kecil, yang berisiko menimbulkan masalah *overfitting*, di mana tingkat kesalahan pada data validasi lebih tinggi daripada pada data pelatihan. Sebaliknya, model dalam penelitian ini dapat mengurangi risiko *overfitting* dan mencapai akurasi yang lebih tinggi, yang menunjukkan bahwa pendekatan hybrid CNN-SVM lebih efektif dalam mengklasifikasikan penyakit pada daun padi, terutama ketika diterapkan pada dataset yang lebih besar dan lebih beragam.

4. Pembahasan

Confusion Matrix pada Gambar 2 menunjukkan bahwa beberapa kelas mengalami tingkat kesalahan prediksi yang signifikan, terutama pada kelas *Narrow Brown Leaf Spot*, yang memiliki 12 sampel salah diklasifikasikan sebagai *Brown Spot*, serta kesalahan lainnya pada beberapa kelas. Hal ini menunjukkan bahwa model mengalami kesulitan dalam membedakan kelas-kelas yang memiliki karakteristik visual serupa, seperti pola gejala dan intensitas warna antara *Narrow Brown Leaf Spot* dan *Brown Spot*. Kesalahan serupa juga terjadi pada kelas *Bacterial Leaf Blight*, di mana beberapa sampel salah diklasifikasikan sebagai *Leaf Blast* atau *Sheath Blight*, mengindikasikan tantangan model dalam menangkap fitur yang cukup spesifik untuk membedakan antar kelas.

Berdasarkan *Classification Report Heatmap* pada Gambar 3 memberikan gambaran lebih mendalam terkait kemampuan model dalam mengenali setiap kelas penyakit. Kelas seperti Neck Blast menunjukkan performa optimal dengan nilai precision, recall, dan f1-score yang semuanya mencapai 1, mengindikasikan bahwa model hampir tidak melakukan kesalahan prediksi untuk kelas ini. Hal ini kemungkinan dipengaruhi oleh pola visual kelas tersebut yang lebih unik dan jelas dibandingkan kelas lain, sehingga memudahkan model dalam membedakannya. Sebaliknya, kelas *Narrow Brown Leaf Spot* memiliki nilai recall yang lebih rendah, yaitu 0,84, dibandingkan precision yang mencapai 0,97. Hal ini menunjukkan bahwa meskipun model cukup baik dalam

memprediksi data yang benar-benar berasal dari kelas ini, ada beberapa sampel Narrow Brown Leaf Spot yang gagal terdeteksi dengan benar dan diklasifikasikan sebagai kelas lain. Penurunan recall ini selaras dengan temuan sebelumnya pada confusion matrix, di mana sebagian besar kesalahan prediksi kelas Narrow Brown Leaf Spot terjadi karena kemiripannya dengan kelas Brown Spot. Kedua kelas ini memiliki karakteristik visual yang serupa, seperti pola bercak dan warna daun, yang membuat model kesulitan membedakannya.

Selain itu, kesalahan ini dapat dipengaruhi oleh distribusi data yang tidak merata, sehingga model kurang terlatih untuk mengenali pola-pola spesifiknya. Noise dalam data gambar, seperti variasi pencahayaan, sudut pengambilan gambar, atau kualitas gambar, juga dapat berkontribusi pada penurunan performa pada kelas ini. Oleh karena itu, upaya peningkatan performa model pada kelas Narrow Brown Leaf Spot dapat dilakukan melalui augmentasi data lebih lanjut, pengumpulan lebih banyak sampel kelas ini, atau pengembangan teknik pra-pemrosesan data yang lebih canggih untuk mengurangi noise dan meningkatkan konsistensi fitur visual serta melakukan pengoptimalan fitur yang di ekstrak oleh model. Secara keseluruhan, *confusion matrix* dan *classification report heatmap* ini membuktikan bahwa model memiliki akurasi yang tinggi dalam mengklasifikasikan sebagian besar kelas penyakit pada daun padi. Namun, untuk kelas-kelas tertentu, model masih membutuhkan penyempurnaan agar dapat meningkatkan akurasi dan menurunkan kesalahan klasifikasi.

Pada Tabel 1 dapat dilihat model memiliki akurasi sebesar 0.95 atau sekitar 95% lalu nilai *macro average* dan *weighted average* dari metrik *precision*, *recall*, dan *F1-Score* juga berada pada angka 0,95. Nilai *macro average* diperoleh dengan menghitung rata-rata *precision*, *recall*, dan *F1-Score* di semua kelas tanpa memperhitungkan jumlah sampel di setiap kelas. Nilai ini menunjukkan seberapa baik model dalam mengenali setiap kelas secara setara, terlepas dari distribusi data antar kelas. Sementara itu, *weighted average* dihitung dengan mempertimbangkan jumlah sampel pada setiap kelas, memberikan bobot lebih tinggi pada kelas dengan jumlah sampel yang lebih besar. Nilai ini mencerminkan performa model secara keseluruhan dengan mempertimbangkan proporsi data di setiap kelas.

Dengan nilai yang tinggi pada kedua jenis rata-rata ini, dapat disimpulkan bahwa model memiliki performa yang seimbang di seluruh kelas (berdasarkan *macro average*), sekaligus mempertahankan performa yang kuat pada kelas-kelas dengan jumlah sampel yang lebih besar (berdasarkan *weighted average*). Hal ini sangat penting untuk penerapan praktis, karena menunjukkan bahwa model dapat mengenali berbagai kategori dengan efektif tanpa adanya bias yang signifikan terhadap kelas tertentu. Secara keseluruhan, akurasi tinggi dan kestabilan nilai metrik ini menunjukkan potensi kuat dari model untuk diimplementasikan pada kasus nyata yang memerlukan klasifikasi data yang andal dan akurat.

5. Penutup

Penelitian ini berhasil mengembangkan model klasifikasi penyakit daun padi menggunakan pendekatan hybrid CNN-SVM yang mencapai akurasi tinggi, yaitu 95% pada data uji. Model menunjukkan performa unggul dalam mendeteksi berbagai jenis penyakit daun padi, dengan *precision*, *recall*, dan *F1-score* rata-rata di atas 0,90, yang menunjukkan keakuratan, ketepatan, dan sensitivitas yang sangat baik pada sebagian besar kelas. Evaluasi menggunakan confusion matrix dan classification report mengindikasikan kemampuan klasifikasi yang kuat, meskipun terdapat beberapa keterbatasan yang perlu diperhatikan. Salah satu keterbatasan utama adalah kesulitan model dalam membedakan kelas dengan karakteristik visual yang serupa, seperti Narrow Brown Leaf Spot yang sering salah diklasifikasikan sebagai Brown Spot. Hal ini menunjukkan bahwa model masih kesulitan menangkap fitur-fitur unik yang membedakan kelas-kelas tersebut. Selain itu, distribusi data yang tidak merata, dengan beberapa kelas memiliki jumlah sampel yang jauh lebih sedikit dibandingkan kelas lain, turut memengaruhi performa model, terutama pada kelas dengan jumlah data yang lebih sedikit. Noise dalam data gambar,

seperti variasi pencahayaan, sudut pengambilan gambar, atau kualitas gambar, juga menjadi faktor yang dapat memengaruhi akurasi prediksi model.

Untuk mengatasi keterbatasan ini, penelitian lebih lanjut disarankan untuk memperluas dataset dengan menambahkan lebih banyak variasi citra pada setiap kelas guna meningkatkan representasi data dan mengurangi ketidakseimbangan. Teknik augmentasi data yang lebih komprehensif juga dapat membantu mengurangi risiko overfitting dan meningkatkan ketahanan model terhadap variasi lingkungan. Selain itu, eksplorasi arsitektur CNN yang lebih kompleks atau teknik ekstraksi fitur yang lebih spesifik dapat memperbaiki kinerja model, terutama untuk kelas-kelas dengan kemiripan visual tinggi. Melakukan integrasi model ke dalam aplikasi berbasis mobile atau web juga dapat mempermudah deteksi penyakit daun padi secara cepat dan efektif di lapangan sehingga dapat membantu petani mengurangi risiko gagal panen.

6. Referensi

- [1] N. A. Mohidem, N. Hashim, R. Shamsudin, and H. C. Man, "Rice for food security: Revisiting its production, diversity, rice milling process and nutrient content," *Agriculture (Switzerland)*, vol. 12, no. 6, p. 741, 2022, doi: 10.3390/agriculture12060741.
- [2] Badan Pusat Statistik, "Luas Panen Padi Tahun 2024 Diperkirakan Sebesar 10,05 Juta Hektare dengan Produksi Padi Sekitar 52,66 Juta Ton Gabah Kering Giling (GKG)," 15 Okt. 2024. [Online]. Available: <https://www.bps.go.id/id/pressrelease/2024/10/15/2376/luas-panen-padi-tahun-2024-diperkirakan-sebesar-10-05-juta-hektare-dengan-produksi-padi-sekitar-52-66-juta-ton-gabah-kering-giling--gkg--.html>. [Access: 10 Nov. 2024].
- [3] M. Aria, M. R. A. Muhammad, Y. A. Yufis, and V. R. S. N. Vinna, "Disease detection on rice leaves through deep learning with InceptionV3 method," *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, vol. 7, no. 5, pp. 1147–1154, 2023, doi: 10.29207/resti.v7i5.4344.
- [4] L. Shanti, G. L. Devi, G. Kumar, and H. Shashidhar, "Molecular Marker-Assisted Selection: A Tool for Insulating Parental Lines of Hybrid Rice Against Bacterial Leaf Blight," *International Journal of Plant Pathology*, vol. 1, pp. 114–123, Mar. 2010, doi: 10.3923/ijpp.2010.114.123.
- [5] U. N. Oktaviana, R. Hendrawan, A. D. K. Annas, and G. W. Wicaksono, "Klasifikasi penyakit padi berdasarkan citra daun menggunakan model terlatih ResNet101," *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, vol. 5, no. 6, pp. 1216–1222, 2021, doi: 10.29207/resti.v5i6.3607.
- [6] A. Jinan and B. H. Hayadi, "Klasifikasi penyakit tanaman padi menggunakan metode convolutional neural network melalui citra daun (multilayer perceptron)," *Journal of Computer and Engineering Science*, vol. 1, no. 2, 2022.
- [7] S. Zahrah, R. Saptono, and E. Suryani, "Identifikasi gejala penyakit padi menggunakan operasi morfologi citra," dalam *Seminar Nasional Ilmu Komputer*, 2016.
- [8] S. Sheila, I. Permata Sari, A. . Bagas Saputra, M. Kharil Anwar, and F. Restu Pujianto, "Detection of Diseases in Rice Leaves Based on Image Processing Using the Convolutional Neural Network (CNN) Method," *JURNAL MULTIMEDIA NETWORKING INFORMATICS*, vol. 9, no. 1, pp. 27–34, Apr. 2023.
- [9] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [10] M. Z. Alom, T. M. Taha, C. Yakopcic, S. Westberg, P. Sidike, M. S. Nasrin, M. Hasan, B. C. Van Essen, A. A. S. Awwal, and V. K. Asari, "A state-of-the-art survey on deep learning theory and architectures," *Electronics*, vol. 8, no. 3, p. 292, 2019, doi: 10.3390/electronics8030292.
- [11] S. Yuliany, Aradea, and A. Nur Rachman, "Implementasi deep learning pada sistem klasifikasi hama tanaman padi menggunakan metode convolutional neural network (CNN)," *Jurnal Buana Informatika*, vol. 13, no. 1, 2022.
- [12] S. V. Darshan, "Automated diagnosis and cataloguing of foliar disease in apple trees using ensemble of deep neural networks," *International Research Journal of Engineering and Technology*, vol. 7, no. 5, pp. 4230–4237, 2020.

- [13] M. Alkhaleefah and C. -C. Wu, "A Hybrid CNN and RBF-Based SVM Approach for Breast Cancer Classification in Mammograms," 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Miyazaki, Japan, 2018, pp. 894-899, doi: 10.1109/SMC.2018.00159.
- [14] U. Syaripudin, D. Suparman, Y. A. Gerhana, A. P. Rahayu, M. Mintarsih, and R. Alawiyah, "Chatbot for signaling Quranic verses science using support vector machine algorithm" *Jurnal Online Informatika*, vol. 6, no. 2, p. 225, 2021, doi: 10.15575/join.v6i2.827.
- [15] M. I. Fikri, T. S. Sabrila, Y. Azhar, and U. M. Malang, "Perbandingan metode Naïve Bayes dan Support Vector Machine pada analisis sentimen Twitter," *SMATIKA: STIKI Informatika Jurnal*, vol. 10, no. 2, pp. 71-76, 2020, doi: 10.32664/smatika.v10i02.455.
- [16] R. A. Saputra, S. Wasyianti, A. Supriyatna, and D. F. Saefudin, "Penerapan algoritma convolutional neural network dan arsitektur MobileNet pada aplikasi deteksi penyakit daun padi," *JURNAL SWABUMI*, vol. 9, no. 2, pp. 185-189, 2021, doi: 10.31294/swabumi.v9i2.11678.
- [17] R. Suhendra, I. Juliwardi, and Sanusi, "Identifikasi dan klasifikasi penyakit daun jagung menggunakan support vector machine," *Jurnal Teknologi Informasi*, vol. 1, no. 1, pp. 29-35, 2022, doi: 10.35308/v1i1.5520.
- [18] A. A. Mujiono, Kartini, and E. Y. Puspaningrum, "Implementasi model hybrid CNN-SVM pada klasifikasi kondisi kesegaran daging ayam," *Jurnal Mahasiswa Teknik Informatika*, vol. 8, no. 1, 2024, doi: 10.36040/jati.v8i1.8855.
- [19] [A. D. Putro and H. Tantyoko, "Hybrid algoritma VGG16-Net dengan Support Vector Machine untuk klasifikasi jenis buah dan sayuran," *Jurnal Teknologi Informasi dan Multimedia (JTIM)*, vol. 5, no. 2, pp. 56-65, Jul. 2023, doi: 10.35746/jtim.v5i2.335.
- [20] C. Schröer, F. Kruse, and J. M. Gómez, "A systematic literature review on applying CRISP-DM process model," *Procedia Computer Science*, vol. 181, pp. 526-534, 2021, doi: 10.1016/j.procs.2021.01.199.
- [21] Y. Itadori, "Rice leaf dataset: Detecting rice leaf diseases," 2023. [Online]. Available: <https://www.kaggle.com/datasets/loki4514/rice-leaf-diseases-detection>. [Access: 10 Sep. 2024].