

IDENTIFIKASI PENYAKIT DAUN PADI DENGAN METODE TRANSFER LEARNING MOBILENET - SUPPORT VECTOR MACHINE

Denis Lizard Sambawo Dimara, Basuki Rahmat, Hendra Maulana
Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur
Jalan Rungkut Madya No.1, Surabaya, Indonesia
dimaradenis.yt@gmail.com

ABSTRAK

Padi adalah komoditas utama dalam sektor pertanian Indonesia yang sangat rentan terhadap penyakit seperti brown spot, bacterial blight, blast, dan tungro, yang dapat menurunkan hasil panen secara signifikan. Proses identifikasi penyakit secara manual oleh petani dinilai kurang efisien dan sering kali menghasilkan kesalahan. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit pada daun padi dengan menggunakan teknologi transfer learning, yang menggabungkan MobileNetV3-Small dan Support Vector Machine (SVM). Metode yang diterapkan mencakup pemrosesan dataset citra daun padi yang meliputi empat jenis penyakit, serta penggunaan teknik augmentasi data untuk meningkatkan keragaman dan kualitas data pelatihan. Hasil evaluasi menunjukkan bahwa kombinasi MobileNetV3-Small dan SVM memberikan akurasi tertinggi yaitu 99,66%, yang lebih unggul dibandingkan model MobileNetV3-Small 99,24% dan SVM 95,02% secara terpisah. Berdasarkan analisis confusion matrix, model ini terbukti sangat akurat dalam mengklasifikasikan penyakit meskipun ada beberapa kesalahan pada kelas-kelas dengan kesamaan visual yang tinggi.

Kata kunci : Mobilenet, Transfer Learning, Support Vector Machine, Deep Learning, Tanaman Padi, Convolutional Neural Network

1. PENDAHULUAN

Padi merupakan komoditas strategis dalam sektor pertanian Indonesia yang berperan penting dalam ketahanan pangan nasional. Namun, produktivitasnya kerap menurun akibat serangan penyakit seperti *brown spot*, *bacterial blight*, *blast* dan *tungro* yang dapat menurunkan hasil panen secara signifikan [1]. Identifikasi penyakit secara manual oleh petani dinilai kurang efektif karena bersifat subjektif dan rentan kesalahan. Oleh karena itu, teknologi *machine learning* menjadi solusi potensial dalam mengidentifikasi penyakit tanaman secara cepat dan akurat [2].

Salah satu pendekatan yang menjanjikan adalah kombinasi *Convolutional Neural Network* (CNN) - *Support Vector Machine* (SVM). CNN efektif dalam mengekstraksi fitur citra, sementara SVM andal dalam klasifikasi data kompleks [3]. *MobileNet*, sebagai arsitektur CNN yang ringan dan efisien, dinilai cocok untuk perangkat dengan sumber daya terbatas [4]. Penelitian ini bertujuan mengembangkan model klasifikasi penyakit daun padi menggunakan *MobileNet* dan SVM, yang diharapkan dapat menjadi fondasi awal dalam pemanfaatan teknologi cerdas untuk mendukung produktivitas pertanian nasional.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Sonmez melakukan penelitian untuk meningkatkan efisiensi dalam pemilihan hibrida gandum menggunakan pendekatan gabungan antara model deep learning *MobileNetv2* dan *GoogleNet*, serta *Support Vector Machine* (SVM). Penelitian ini bertujuan untuk mengidentifikasi dan mengklasifikasikan varietas serta hibrida gandum dengan akurasi tinggi menggunakan gambar biji

gandum. Hasil penelitian menunjukkan akurasi klasifikasi sebesar 99,26% untuk *MobileNetv2* dan 97,41% untuk *GoogleNet*. Setelah menerapkan metode SVM pada fitur yang diekstraksi, akurasi tertinggi yang dicapai mencapai 99,91%. Pendekatan ini mempercepat proses identifikasi hibrida gandum dan mendukung program pemuliaan serta manajemen tanaman [5]

Ogundokun mengembangkan model deep transfer learning (DTL) berbasis *MobileNet-SVM* untuk mendiagnosis gambar histologi kanker payudara (BCH) dari dataset *BreakHis v1 400x*. Penelitian ini bertujuan untuk meningkatkan akurasi deteksi kanker payudara melalui pendekatan IoMT dengan menggunakan model ringan yang cocok untuk aplikasi medis. Hasil eksperimen menunjukkan akurasi pelatihan mencapai 100% dan akurasi pengujian sebesar 91%, dengan F1-score 91,35%. Model ini menunjukkan efisiensi yang luar biasa dalam klasifikasi gambar kanker dengan AUC 91,5%, menandakan kemampuannya yang sangat baik dalam deteksi kanker [6]

2.2. Padi

Tanaman padi adalah salah satu komoditas pertanian yang memiliki peranan penting dalam penyediaan pangan di banyak negara, khususnya di Indonesia. Padi dikenal sebagai bahan pokok utama yang menghasilkan beras, yang merupakan sumber utama karbohidrat bagi sebagian besar penduduk dunia [7].

2.3. Machine Learning

Machine learning merupakan cabang dari kecerdasan buatan (*Artificial Intelligence*) yang berfokus pada pengembangan algoritma dan model

yang memungkinkan sistem untuk belajar dari data secara otomatis tanpa diprogram secara eksplisit. Dalam konteks ini, “belajar” merujuk pada kemampuan sistem untuk mengenali pola, membangun representasi, serta meningkatkan performa seiring bertambahnya jumlah data dan pengalaman. Algoritma *machine learning* digunakan dalam berbagai aplikasi, seperti deteksi penipuan, rekomendasi produk, dan pengenalan pola dalam data medis. Berdasarkan pendekatannya, *machine learning* terbagi menjadi *supervised learning*, *unsupervised learning*, dan *reinforcement learning*. [8].

2.4. Deep Learning

Deep learning adalah pendekatan lanjutan dari *machine learning* yang menggunakan arsitektur jaringan saraf tiruan (*artificial neural networks*) dengan banyak lapisan tersembunyi (*hidden layers*), yang dikenal sebagai *deep neural networks*. Dengan kedalaman arsitektur ini, model *deep learning* mampu mempelajari representasi fitur yang kompleks dan hierarkis dari data mentah, sehingga sangat efektif untuk menangani permasalahan yang melibatkan data tidak terstruktur seperti gambar, suara, dan teks. Salah satu keunggulan *deep learning* adalah kemampuannya dalam melakukan *feature extraction* secara otomatis tanpa perlu rekayasa fitur manual, yang sangat bermanfaat dalam domain seperti *computer vision* dan pemrosesan bahasa alami. [9].

2.5. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah jenis *jaringan saraf tiruan* yang dirancang khusus untuk pengolahan data berbentuk *grid*, seperti gambar [10]. CNN terdiri dari beberapa lapisan utama, yaitu *lapisan konvolusi*, *lapisan aktivasi* (seperti *ReLU*), *lapisan pooling*, dan *lapisan fully connected*. *Lapisan konvolusi* berperan dalam mengekstraksi fitur lokal dari citra, seperti tepi, sudut, atau tekstur, sedangkan *lapisan pooling* mereduksi dimensi fitur untuk efisiensi komputasi dan mencegah *overfitting*. CNN telah terbukti sangat handal dalam berbagai tugas pengenalan objek, klasifikasi gambar, deteksi wajah, dan segmentasi citra, karena kemampuannya dalam mengenali pola spasial dan visual dengan akurasi tinggi.

2.6. MobilenetV3-Small

MobileNetV3-Small merupakan arsitektur CNN ringan yang dikembangkan oleh Google dengan menggabungkan teknik-teknik efisiensi seperti *depthwise separable convolution* dan *squeeze-and-excitation*. Versi “Small” dari *MobileNetV3* dirancang untuk dijalankan pada perangkat dengan sumber daya terbatas, seperti ponsel pintar dan *embedded systems*, tanpa mengorbankan kinerja secara signifikan [11]. Model ini juga menggunakan *Neural Architecture Search (NAS)* untuk menemukan struktur jaringan yang optimal, serta teknik *h-swish activation* untuk efisiensi komputasi. *MobileNetV3-Small* banyak

digunakan dalam aplikasi *real-time* seperti deteksi objek dan klasifikasi gambar di perangkat *edge* karena keseimbangan antara akurasi dan kecepatan *inferensi*.

2.7. Support Vector Machine

Support Vector Machine (SVM) adalah algoritma klasifikasi yang kuat dalam memisahkan dua atau lebih kelas dengan menentukan *hyperplane* optimal di ruang fitur. SVM bekerja berdasarkan prinsip *margin maksimum*, yaitu memilih *hyperplane* yang memaksimalkan jarak antara kelas yang berbeda. Keunggulan utama SVM adalah kemampuannya dalam menangani data berdimensi tinggi dan tetap efektif dalam kasus jumlah sampel yang terbatas. Dengan *kernel trick*, SVM juga dapat menyelesaikan masalah non-linear melalui pemetaan data ke ruang fitur berdimensi lebih tinggi. Aplikasi SVM meliputi pengenalan wajah, *bioinformatika*, dan deteksi *intrusi jaringan*. [12].

2.8. Confusion Matrix

Confusion matrix adalah alat evaluasi yang digunakan untuk mengukur kinerja model klasifikasi dengan menampilkan jumlah prediksi yang benar dan salah berdasarkan kelas aktual dan prediksi. Matriks ini terdiri dari empat komponen utama: *true positive (TP)*, *false positive (FP)*, *true negative (TN)*, dan *false negative (FN)*. Dari nilai-nilai ini, dapat dihitung metrik evaluasi seperti *akurasi*, *presisi*, *recall*, dan *F1-score*. *Confusion matrix* sangat penting untuk mengevaluasi model secara menyeluruh, terutama pada data yang tidak seimbang, karena memberikan informasi rinci tentang jenis kesalahan yang dilakukan oleh model. [13].

2.9. Transfer Learning

Transfer learning adalah pendekatan dalam *deep learning* yang memanfaatkan model yang telah dilatih sebelumnya (*pre-trained models*) pada tugas yang besar, seperti *ImageNet*, untuk digunakan kembali dalam tugas yang serupa dengan data terbatas. Dengan cara ini, pengetahuan yang telah dipelajari oleh model, terutama pada lapisan awal yang menangkap fitur umum, dapat digunakan untuk mempercepat pelatihan dan meningkatkan akurasi model baru. *Transfer learning* sangat berguna ketika tidak tersedia cukup data untuk melatih model dari awal, seperti dalam klasifikasi gambar medis atau identifikasi penyakit tanaman. [14].

2.10. TensorFlow


TensorFlow adalah *framework open-source* yang dikembangkan oleh Google untuk membangun dan melatih model *machine learning* dan *deep learning*. *TensorFlow* menyediakan berbagai abstraksi tingkat tinggi seperti *Keras*, serta kontrol tingkat rendah untuk membangun model secara lebih fleksibel. Dengan dukungan komputasi numerik berbasis *graph* dan eksekusi berbasis *GPU/TPU*, *TensorFlow* sangat cocok digunakan dalam pelatihan dan *deployment*

model skala besar. Selain itu, komunitas yang besar dan dokumentasi yang luas menjadikan *TensorFlow* sebagai pilihan utama dalam riset dan pengembangan aplikasi AI di berbagai bidang. [15].

2.10 Augmentasi Data

Augmentasi data adalah teknik yang digunakan untuk meningkatkan jumlah dan keragaman data pelatihan dengan cara menerapkan transformasi tertentu pada data asli, seperti rotasi, *flipping* horizontal/vertikal, *zoom*, *cropping*, atau perubahan pencahayaan. Teknik ini sangat penting untuk mencegah *overfitting*, yaitu kondisi di mana model terlalu menyesuaikan diri dengan data pelatihan dan gagal mengeneralisasi pada data baru. [16]. Dalam penelitian ini, *augmentasi data* diterapkan untuk memperkaya variasi visual citra penyakit daun padi, sehingga memungkinkan model untuk belajar fitur yang lebih *robust* dan akurat dalam klasifikasi meskipun jumlah data terbatas.

3. METODE PENELITIAN



Gambar 1. Alur Penelitian

Pada Gambar 1 diperlihatkan alur penelitian yang akan dilakukan, yang mencakup beberapa tahapan utama, yaitu studi literatur, praproses data, perancangan model, dan evaluasi performa model. Setiap tahapan tersebut telah dirancang secara sistematis untuk memastikan kelancaran proses penelitian, mengikuti urutan yang telah ditetapkan.

3.1. Studi Literatur

Studi literatur ini bertujuan untuk mengkaji pendekatan klasifikasi penyakit daun padi menggunakan citra digital, dengan penekanan pada algoritma *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM). Melalui tinjauan terhadap berbagai sumber ilmiah dan teknologi pengolahan citra, diperoleh pemahaman mengenai keunggulan CNN dalam ekstraksi fitur secara otomatis serta efektivitas SVM dalam proses klasifikasi. Pemahaman ini menjadi landasan dalam merancang metode yang lebih akurat dan efisien untuk penelitian yang akan datang.


3.2. Dataset Persiapan

Dataset yang digunakan dalam penelitian ini terdiri dari citra daun padi yang mengandung empat jenis penyakit utama, yaitu *bacterial blight*, *blast*, *brown spot*, dan *tungro*. Setiap citra pada dataset ini telah dikategorikan sesuai dengan jenis penyakit yang ada pada daun padi, yang memungkinkan model untuk mempelajari dan mengidentifikasi karakteristik masing-masing penyakit secara lebih akurat. Contoh sampel dataset dapat dilihat pada Tabel 1 berikut.

Tabel 1. Sampel Citra Dataset Penyakit Daun Padi


No.	Jenis Penyakit	Citra Sampel Daun Padi
1	<i>bacterial blight</i>	
2	<i>blast</i>	
3	<i>brown spot</i>	
4	<i>tungro</i>	

Dataset ini diperoleh dari platform Kaggle dan terdiri dari total 5.932 citra. Citra tersebut terbagi dalam beberapa kelas, yaitu 1.584 citra untuk kelas *bacterial light*, 1.440 citra untuk kelas *blash*, 1.600 citra untuk kelas *brownspot*, dan 1.308 citra untuk kelas *tungro*. Penyebaran dataset dapat dilihat pada Gambar 2 berikut.



Gambar 2. Penyebaran Dataset

3.3. Praproses Data



Gambar 3. Alur Praproses Data


Pada Gambar 3 diperlihatkan alur praproses data yang mencakup beberapa tahapan penting sebelum merancang model klasifikasi, guna memastikan kualitas dan kesiapan data. Proses dimulai dengan membagi dataset menjadi tiga bagian, yakni 70% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data pengujian. Selanjutnya, data tersebut disesuaikan dengan input model MobileNet yang berukuran 224 x 224 piksel, yang akan digunakan sebagai input dalam program. Pembagian data ini dilakukan dengan tujuan untuk menghindari overfitting dan meningkatkan akurasi evaluasi model.



Gambar 4. Sampel Data Augmentasi

Gambar 4 menunjukkan salah satu sampel data yang telah mengalami proses *data augmentation*. Teknik ini diterapkan untuk memperluas variasi data pelatihan melalui transformasi citra, seperti rotasi dan perubahan skala. Beberapa metode augmentasi yang digunakan meliputi *rotation range*, *width shift range*, *height shift range*, dan *zoom range*. Setelah proses augmentasi, dilakukan normalisasi data guna menyamakan rentang nilai piksel, sehingga seluruh citra berada dalam skala yang seragam. Langkah normalisasi ini bertujuan untuk meningkatkan stabilitas dan efisiensi selama proses pelatihan model. Setiap tahapan dalam proses ini dirancang untuk mendukung kinerja optimal dari model yang dikembangkan..

3.4. Perancangan Model



Gambar 5. Alur Perancangan Model

Gambar 5 menunjukan alur perancangan model dalam penelitian ini. Proses dimulai dengan tahap praproses data yang menghasilkan dataset yang telah siap untuk digunakan. Data yang telah diproses kemudian digunakan untuk melatih tiga model yang berbeda, yaitu kombinasi model *MobileNetV3-Small* dengan SVM, model *MobileNetV3-Small*, dan model SVM secara terpisah. Setelah pelatihan, masing-masing model dievaluasi untuk mengukur kinerjanya dalam tugas klasifikasi. Evaluasi model dilakukan untuk menilai akurasi dan performa setiap model, yang kemudian dapat dibandingkan untuk memilih model terbaik dalam penerapan pada data yang ada.

3.5. Evaluasi Performa Model

Tahap evaluasi performa model merupakan langkah krusial dalam penelitian ini untuk menilai tingkat akurasi dan keandalan model dalam mengklasifikasikan citra daun padi. Model yang telah dilatih sebelumnya akan diuji menggunakan *confusion matrix* serta metrik evaluasi, dengan akurasi sebagai tolok ukur utama. Evaluasi dilakukan terhadap model CNN-SVM, baik saat diterapkan secara hybrid maupun secara terpisah, untuk membandingkan performa dari masing-masing pendekatan. Metrik evaluasi yang digunakan antara lain adalah akurasi, presisi, *recall* dan *F1-score*. Berikut adalah persamaan yang digunakan untuk menghitung metrik-metrik tersebut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$Precision = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

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

$$F1-Score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (4)$$

Keterangan:

TP = True Positive

FP = False Positive

TN = True Negative

FN = False Negative

4. HASIL DAN PEMBAHASAN


Pada bab ini, akan dibahas hasil dari penerapan model klasifikasi penyakit daun padi menggunakan kombinasi *MobileNetV3-Small* dan *Support Vector Machine* (SVM), yang telah diuji dan dievaluasi berdasarkan akurasi serta kinerjanya. Sebelum membahas evaluasi dari setiap model, yaitu Model *MobileNetV3-Small* - SVM, Model *MobileNetV3-Small*, dan Model SVM secara terpisah, hasil evaluasi akan dibagi ke dalam beberapa bagian untuk memberikan gambaran yang jelas mengenai perbandingan antara model-model tersebut. Evaluasi ini bertujuan untuk menilai sejauh mana setiap model mampu mengklasifikasikan citra penyakit daun padi dengan akurat, serta mengidentifikasi kelebihan dan kekurangan masing-masing model dalam menghadapi tantangan klasifikasi citra penyakit tanaman.

4.1 Evaluasi Model Mobilenet – SVM

Pada subbab ini, dilakukan evaluasi terhadap performa model yang mengintegrasikan arsitektur *MobileNetV3-Small* dengan *Support Vector Machine* (SVM) untuk klasifikasi penyakit pada daun padi. Proses dimulai dengan penggunaan *MobileNetV3-Small* sebagai ekstraktor fitur, yang dipilih karena efisiensinya dalam memproses citra pada perangkat dengan sumber daya terbatas. Setelah membekukan lapisan-lapisan model *MobileNetV3-Small*, fitur-fitur yang diekstraksi digunakan sebagai input untuk model SVM dengan kernel linear dan parameter C sebesar 0.1, yang dilatih menggunakan dataset pelatihan. Model kemudian diuji pada data validasi dan pengujian, dengan evaluasi dilakukan menggunakan metrik seperti akurasi, *precision*, *recall*, dan *F1-score*. Selain itu, dilakukan analisis lebih lanjut menggunakan *confusion matrix* untuk memberikan gambaran mendalam mengenai kinerja model dalam mengidentifikasi penyakit pada daun padi.

Gambar 6 menunjukkan *confusion matrix* yang menggambarkan hasil evaluasi model *MobileNetV3-Small* yang digabungkan dengan SVM dalam mengklasifikasikan empat jenis penyakit pada daun padi. Model ini menunjukkan performa yang sangat baik, dengan jumlah prediksi yang benar (True Positives) untuk setiap kelas yang sangat tinggi. Sebanyak 287 citra dari kelas *Bacterial Blight*, 294

citra dari *Blast*, 317 citra dari *Brownspot*, dan 286 citra dari *Tungro* berhasil diklasifikasikan dengan benar. Meskipun demikian, terdapat sedikit kesalahan, seperti satu citra *Blast* yang salah diklasifikasikan sebagai *Bacterial Blight*, serta beberapa citra *Brownspot* yang salah diklasifikasikan sebagai *Blast*.



Gambar 6. Confusion Matrix MobilenetV3-Small – SVM

Tabel 2. Classification Report MobilenetV3-Small - SVM

	Precision	Recall	F1-Score	Support
BacterialBlight	1.00	1.00	1.00	287
Blast	0.99	1.00	0.99	295
Brownspot	1.00	0.99	1.00	320
Tungro	1.00	1.00	1.00	286
Accuracy			1.00	1188
Macro Avg	1.00	1.00	1.00	1188
Weighted AVG	1.00	1.00	1.00	1188

Pada Tabel 2 menyajikan laporan klasifikasi yang menunjukkan bahwa model *MobileNetV3-Small* - SVM memiliki performa yang sangat baik dengan akurasi 1.00. Setiap kelas mencapai nilai *precision*, *recall*, dan *F1-score* yang sangat tinggi, mencerminkan kemampuan model dalam melakukan klasifikasi yang akurat dan konsisten.

Tabel 3. Tabel Waktu dan Memori MobilenetV3-Small – SVM

EVALUASI WAKTU & MEMORI	
Waktu Eksekusi	165.79 detik
Penggunaan Memori Saat Ini	1134.00 MB
Penggunaan Memori Puncak	2629.27 MB


Pada tabel 3 menyajikan evaluasi waktu dan penggunaan memori untuk model *MobileNetV3-Small* - SVM. Waktu eksekusi model tercatat sebesar 165.79 detik, dengan penggunaan memori saat ini sebesar 1134.00 MB dan memori puncak mencapai 2629.27 MB. Ini menunjukkan efisiensi model baik dalam hal waktu eksekusi maupun penggunaan memori. Selain itu, model ini memperoleh hasil akurasi pada data

pengujian sebesar 99.66%, yang menandakan bahwa performa model sangat baik dalam mengklasifikasikan penyakit daun padi.

4.2 Evaluasi Model MobilenetV3-Small

Pada evaluasi model, arsitektur digunakan adalah *MobileNetV3-Small* yang telah dilatih sebelumnya dengan bobot dari *ImageNet* dan tanpa lapisan atas (*fully connected layers*), berfungsi untuk mengekstraksi fitur dari citra. Setelah lapisan-lapisan dasar model *MobileNetV3Small* dibekukan, lapisan tambahan seperti *Batch Normalization*, *Dense*, dan *Dropout* ditambahkan untuk meningkatkan generalisasi dan mencegah overfitting.

Model kemudian disusun dan dikompilasi menggunakan *optimizer Adam* dengan *learning rate* 0.0001 untuk memastikan kestabilan selama pelatihan. Pelatihan dilakukan dengan menggunakan dataset pelatihan dan validasi, diikuti oleh evaluasi akurasi pada data validasi dan pengujian. Untuk mencegah *overfitting* lebih lanjut, diterapkan *callback early stopping* yang memantau *validation loss* dan menghentikan pelatihan jika tidak ada perbaikan setelah beberapa epoch. Hasil evaluasi, yang meliputi akurasi, *confusion matrix*, dan *classification report*, memberikan gambaran mendalam mengenai kinerja model.



Gambar 7. Confusion Matrix MobilenetV3Small

Pada gambar 7 menunjukkan confusion matrix yang menggambarkan hasil evaluasi model *MobileNetV3-Small*. Model ini menunjukkan performa yang sangat baik dalam klasifikasi penyakit daun padi. Untuk kelas *BacterialBlight*, model berhasil mengklasifikasikan 292 citra dengan benar. Pada kelas *Blast*, model mengklasifikasikan 299 citra dengan benar, namun terdapat 4 citra yang salah diklasifikasikan sebagai *BacterialBlight* dan 4 citra lainnya sebagai *Brownspot*. Sementara itu, pada kelas *Brownspot*, model berhasil mengklasifikasikan 317 citra dengan benar, dengan hanya 2 citra yang salah diklasifikasikan sebagai *Blast*. Pada kelas *Tungro*, model berhasil mengklasifikasikan 270 citra dengan benar tanpa adanya kesalahan. Secara keseluruhan,

confusion matrix ini menunjukkan bahwa model *MobileNetV3-Small* memiliki akurasi yang sangat tinggi, dengan sedikit kesalahan, terutama pada kelas-kelas yang memiliki karakteristik visual yang serupa. Hal ini mengindikasikan kemampuan model yang sangat baik dalam membedakan citra pada berbagai kelas, meskipun terdapat beberapa tantangan pada kelas dengan kesamaan visual yang tinggi.

Tabel 4. Classification Report MobilenetV3-Small

	Precision	Recall	F1-Score	Support
BacterialBlight	0.99	1.00	0.99	292
Blast	0.99	0.97	0.98	307
Brownspot	0.99	0.99	0.99	319
Tungro	1.00	1.00	1.00	270
Accuracy			0.99	1188
Macro Avg	0.99	0.99	0.99	1188
Weighted AVG	0.99	0.99	0.99	1188


Tabel 4 menyajikan laporan klasifikasi untuk model *MobileNetV3-Small*, yang menunjukkan bahwa model ini memiliki kinerja yang sangat baik dengan akurasi sebesar 0.99. Setiap kelas, yaitu *Bacterial Blight*, *Blast*, *Brownspot*, dan *Tungro*, mencapai nilai *precision*, *recall*, dan *F1-score* yang tinggi, dengan kelas *Tungro* mencapai nilai sempurna 1.00 pada ketiga metrik. Rata-rata makro dan tertimbang juga menunjukkan nilai 0.99, yang mencerminkan konsistensi dan akurasi model dalam mengklasifikasikan penyakit daun padi. Model ini memperoleh hasil *Validation Accuracy* sebesar 99.75% dan *Test Accuracy* sebesar 99.24%, menandakan bahwa performa model sangat baik dalam pengujian dan validasi.

4.3 Evaluasi Model Support Vector Machine

Pada bagian ini, dilakukan evaluasi terhadap model *Support Vector Machine* (SVM) yang diterapkan untuk identifikasi penyakit pada daun padi. Proses dimulai dengan ekstraksi fitur dari dataset, menggunakan fungsi khusus yang mengonversi gambar menjadi format yang sesuai untuk pemrosesan oleh model SVM. Model SVM yang digunakan memiliki kernel linear dengan parameter $C = 0.1$, dan dilatih menggunakan fitur-fitur yang diekstraksi dari dataset pelatihan. Selanjutnya, evaluasi dilakukan dengan mengukur akurasi model pada data validasi dan pengujian. Hasil evaluasi ini mencakup nilai akurasi, laporan klasifikasi, serta *confusion matrix*.

Pada gambar 8 menunjukkan *matrix confusion* yang menggambarkan hasil klasifikasi yang dilakukan oleh model *Support Vector Machine* (SVM) dengan kernel linear dan parameter $C = 0.1$. Model ini menunjukkan akurasi yang tinggi dalam memprediksi kelas *Brownspot* dan *Tungro*, dengan masing-masing 247 dan 177 data yang terklasifikasi dengan benar. Namun, terdapat sejumlah kesalahan prediksi pada kelas *Bacterialblight*, di mana 2 data salah diklasifikasikan sebagai *Blast*, 2 data sebagai *Brownspot*, dan 4 data sebagai *Tungro*. Selain itu, pada

kelas *Blast*, meskipun 209 data berhasil diprediksi dengan benar, terdapat 6 data yang salah diklasifikasikan sebagai *Bacterialblight* dan 2 data sebagai *Tungro*.



Gambar 8. Confusion Matrix SVM

Tabel 5. Classification Report Support Vector Machine

	Precision	Recall	F1-Score	Support
BacterialBlight	0.94	0.96	0.95	214
Blast	0.93	0.96	0.95	217
Brownspot	0.96	0.99	0.98	249
Tungro	0.97	0.87	0.92	203
Accuracy			0.95	883
Macro Avg	0.95	0.95	0.95	883
Weighted AVG	0.95	0.95	0.95	883

Tabel 5 menunjukkan hasil Classification Report untuk model Support Vector Machine (SVM), yang menggambarkan kinerja model secara keseluruhan. Model ini menunjukkan performa yang sangat baik dengan accuracy sebesar 95%, serta nilai *precision*, *recall*, dan *F1-score* yang tinggi dan konsisten di seluruh kelas. Kelas *Brownspot* menunjukkan performa terbaik dengan *precision* 0.96 dan *recall* 0.99, sementara kelas *Tungro* memiliki *recall* terendah 0.87, meskipun tetap mempertahankan *precision* yang tinggi yaitu 0.97. Secara keseluruhan, model ini memiliki keseimbangan yang baik antara *precision* dan *recall*, dengan *macro average* dan *weighted average* masing-masing mencapai 0.95 untuk ketiga metrik tersebut. Model ini mencapai validation accuracy sebesar 94.75% dan test accuracy sebesar 95.02%.

4.4 Evaluasi Performa Model

Pada bagian ini, dilakukan evaluasi performa dari tiga model yang digunakan untuk klasifikasi penyakit pada daun padi, yaitu model *MobileNetV3-Small* – SVM, *MobileNetV3-Small*, dan SVM. Tujuan dari evaluasi ini adalah untuk membandingkan akurasi, di antara ketiga model, serta untuk memberikan gambaran mengenai kehandalan setiap model dalam

mengklasifikasikan penyakit daun padi. Setiap model diuji menggunakan dataset yang sama dan distribusi data yang sama, dan hasil evaluasi ini akan memberikan wawasan mengenai performa masing-masing model. Tabel 6 di bawah ini menyajikan perbandingan accuracy dari masing-masing model yang dievaluasi.

Tabel 6. Perbandingan Akurasi Model

Model	Distribusi Data	Akurasi
MobileNetV3Small - SVM	70 : 15: 15	99.66%
MobileNetV3Small		99.24%
Support Vector Machine (SVM)		95.02%

Tabel 6 menunjukkan perbandingan akurasi dari tiga model yang digunakan untuk klasifikasi penyakit pada daun padi, yaitu *MobileNetV3-Small* – SVM, *MobileNetV3-Small*, dan *Support Vector Machine* (SVM), dengan distribusi data pelatihan, validasi, dan pengujian sebesar 70:15:15. Model *MobileNetV3-Small* – SVM menunjukkan akurasi tertinggi, yaitu 99.66%, yang mencerminkan kinerja terbaik di antara ketiga model. Sementara itu, model *MobileNetV3-Small* memperoleh akurasi sedikit lebih rendah, yaitu 99.24%, namun tetap menunjukkan performa yang sangat baik meskipun tanpa integrasi dengan SVM. Di sisi lain, model SVM memiliki akurasi terendah, yaitu 95.02%, meskipun masih menunjukkan kinerja yang baik.

5. KESIMPULAN

Penelitian ini berhasil mengembangkan model identifikasi penyakit daun padi yang menggabungkan arsitektur *MobileNetV3-Small* dengan algoritma *Support Vector Machine* (SVM). Model hybrid yang dikembangkan menunjukkan kinerja yang sangat baik dengan akurasi tertinggi mencapai 99,66%. Hal ini dicapai melalui pemilihan *hyperparameter* yang optimal, yaitu nilai *C* sebesar 0,1 dan penggunaan kernel linier pada SVM, yang terbukti menghasilkan performa lebih baik dibandingkan penerapan model *MobileNetV3-Small* (99,24%) maupun SVM (95,02%) secara terpisah. Dataset yang digunakan dalam penelitian ini dibagi dengan rasio 70:15:15 untuk pelatihan, validasi, dan pengujian, guna memastikan evaluasi model yang adil dan menyeluruh, serta untuk menghindari *overfitting* dan meningkatkan kemampuan generalisasi model terhadap data baru yang belum pernah dilihat sebelumnya. Pemanfaatan teknik *transfer learning* pada *MobileNetV3Small* memberikan kontribusi signifikan dalam meningkatkan efisiensi pelatihan, terutama dalam konteks keterbatasan jumlah data pelatihan. Evaluasi performa model menggunakan *confusion matrix* memperlihatkan bahwa model mampu mengklasifikasikan jenis penyakit daun padi dengan tingkat akurasi yang tinggi, meskipun masih terdapat sejumlah kecil kesalahan klasifikasi pada kelas dengan kemiripan visual yang tinggi. Hasil penelitian ini

diharapkan dapat memberikan kontribusi yang signifikan dalam bidang pertanian dan teknologi, khususnya dalam pengembangan sistem deteksi penyakit tanaman secara otomatis yang berpotensi mendukung peningkatan ketahanan pangan nasional. Selain itu, penelitian ini membuka peluang untuk pengembangan lebih lanjut melalui penerapan teknik *data augmentation* serta eksplorasi strategi optimasi *hyperparameter*, guna meningkatkan akurasi dan efisiensi model secara menyeluruh hingga tahap *deployment* di lingkungan nyata.

DAFTAR PUSTAKA

- [1] R. R. A. Siregar and Indrianto, "Detection of brown spot and leaf blight in rice with the You Only Look Once (YOLO) algorithm," *Petir*, vol. 16, no. 1, 2023, doi: 10.33322/petir.v16i1.2003.
- [2] A. R. Vrushali Paithankar, Ajinkya Awari, "Plant Disease Detection using Machine Learning," *International Journal of Advanced Research in Science, Communication and Technology*, pp. 267–272, 2023, doi: 10.48175/ijarsct-9297.
- [3] A. D. Hassan and M. Sabha, "Feature Extraction for Image Analysis and Detection using Machine Learning Techniques," *International Journal of Advanced Networking and Applications*, vol. 14, no. 04, pp. 5499–5508, 2023, doi: 10.35444/ijana.2023.14401.
- [4] C.-Y. Kim, K. Um, and S. W. Heo, "A novel MobileNet with selective depth multiplier to compromise complexity and accuracy," *Etri Journal*, 2022, doi: 10.4218/etrij.2022-0103.
- [5] M. E. Sonmez, "Convolutional neural network-support vector machine-based approach for identification of wheat hybrids," *European Food Research and Technology*, vol. 250, no. 5, pp. 1353–1362, 2024, doi: 10.1007/s00217-024-04473-4.
- [6] R. O. Ogundokun, "MobileNet-SVM: A Lightweight Deep Transfer Learning Model to Diagnose BCH Scans for IoMT-Based Imaging Sensors," *Sensors*, vol. 23, no. 2, 2023, doi: 10.3390/s23020656.
- [7] W.-J. Hong *et al.*, "A Systemic View of Carbohydrate Metabolism in Rice to Facilitate Productivity," vol. 10, no. 8, p. 1690, 2021, doi: 10.3390/PLANTS10081690.
- [8] R. Kumar, "Machine Learning," *International Journal For Science Technology And Engineering*, vol. 10, no. 6, p. 2460, 2022, doi: 10.22214/ijraset.2022.44376.
- [9] M. S. Kyin, Z. Oo, and K. M. Cho, "An Overview Studying of Deep Learning," *Int J Sci Res Sci Eng Technol*, vol. 7, no. 2, pp. 394–398, 2020, doi: 10.32628/IJSRSET207279.
- [10] B. P. Sowmya and M. C. Supriya, "Convolutional Neural Network (CNN) Fundamental Operational Survey," Springer, Cham, 2020, pp. 245–258. doi: 10.1007/978-3-030-65407-8_21.
- [11] X. Liang, J. M. Liang, T. Yin, and X. Tang, "A lightweight method for face expression recognition based on improved MobileNetV3," *IET Image Process*, vol. 17, no. 8, pp. 2375–2384, 2023, doi: 10.1049/ipr2.12798.
- [12] M. Jabardi, "Support vector machines: theory, algorithms, and applications," *Infocommunications Journal*, vol. 17, no. 1, pp. 66–75, 2023, doi: 10.36244/icj.2025.1.8.
- [13] A. Theissler, M. Thomas, M. Burch, and F. Gerschner, "ConfusionVis: Comparative evaluation and selection of multi-class classifiers based on confusion matrices," *Knowledge Based Systems*, vol. 247, p. 108651, 2022, doi: 10.1016/j.knosys.2022.108651.
- [14] A. Ali, M. G. Yaseen, M. Aljanabi, S. A. Abed, and C. Gpt, "Transfer Learning: A New Promising Techniques," pp. 31–32, 2023, doi: 10.58496/mjbd/2023/004.
- [15] A. Hosna, E. Merry, J. Gyalmo, Z. Alom, Z. Aung, and M. A. Azim, "Transfer learning: a friendly introduction," *J Big Data*, vol. 9, no. 1, 2022, doi: 10.1186/s40537-022-00652-w.
- [16] Z. Peng *et al.*, "Data Augmentation for Training Deep Neural Networks," CRC Press, 2021, pp. 151–164. doi: 10.1201/9780429323782-13