

Klasifikasi Kondisi Daun Jeruk Menggunakan *Hybrid MobileNetV3-SVM* Berbasis Citra Digital

Aditya Ali Kusuma^{1*}, Ery Hartati²

¹⁻²Program Studi Informatika, Universitas Multi Data Palembang, Indonesia

Email: Adityaalikusuma_2226250022@mhs.mdp.ac.id^{1*}, ery_hartati@mdp.ac.id²

*Penulis Korespondensi: Adityaalikusuma_2226250022@mhs.mdp.ac.id

Abstract. *Citrus leaf conditions can affect crop quality and productivity if not identified accurately and promptly. Manual identification is often time-consuming and depends on the observer's ability to recognize visual symptoms. This study aims to develop an image-based citrus leaf condition classification model using a Hybrid MobileNetV3-SVM approach and compare its performance with a standalone MobileNetV3-Small model. The dataset consisted of eleven categories of citrus leaf conditions. The data were divided into training, validation, and testing sets using a ratio of 70:15:15. MobileNetV3-Small was employed as a feature extractor through transfer learning and fine-tuning, while a Support Vector Machine (SVM) with a Radial Basis Function (RBF) kernel was used as the classifier in the hybrid model. To address class imbalance, Random Under Sampling (RUS) was applied to the training data before model training. Experimental results showed that the Hybrid MobileNetV3-SVM model achieved an accuracy of 98.18%, precision of 98.20%, recall of 98.18%, and F1-score of 98.18%. In comparison, the standalone MobileNetV3-Small model achieved an accuracy of 97.27%, precision of 97.32%, recall of 97.27%, and F1-score of 97.25%. The results indicate that incorporating SVM improved classification performance and reduced the number of misclassified samples in the testing dataset. Therefore, the Hybrid MobileNetV3-SVM approach can be utilized as an effective method for classifying citrus leaf conditions based on digital images.*

Keywords: *Citrus Leaf Condition Classification; Deep Learning; Image Classification; MobileNetV3-Small; Support Vector Machine.*

Abstrak. Kondisi daun jeruk dapat memengaruhi kualitas dan produktivitas tanaman apabila tidak diidentifikasi secara tepat. Identifikasi secara manual memerlukan waktu serta bergantung pada kemampuan pengamat dalam mengenali karakteristik visual yang muncul pada daun. Penelitian ini bertujuan mengembangkan model klasifikasi kondisi daun jeruk berbasis citra digital menggunakan pendekatan *Hybrid MobileNetV3-SVM* serta membandingkan kinerjanya dengan *MobileNetV3-Small* murni. Dataset yang digunakan terdiri atas sebelas kategori kondisi daun jeruk. Data dibagi menjadi data pelatihan, validasi, dan pengujian dengan rasio 70:15:15. *MobileNetV3-Small* digunakan sebagai ekstraktor fitur melalui transfer learning dan fine-tuning, sedangkan Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF) digunakan sebagai classifier pada model hybrid. Untuk mengatasi ketidakseimbangan jumlah sampel antar kelas, diterapkan Random Under Sampling (RUS) pada data pelatihan sebelum proses pelatihan model. Hasil pengujian menunjukkan bahwa model *Hybrid MobileNetV3-SVM* memperoleh akurasi sebesar 98,18%, precision sebesar 98,20%, recall sebesar 98,18%, dan F1-score sebesar 98,18%. Sementara itu, *MobileNetV3-Small* murni memperoleh akurasi sebesar 97,27%, precision sebesar 97,32%, recall sebesar 97,27%, dan F1-score sebesar 97,25%. Hasil perbandingan menunjukkan bahwa penggunaan SVM mampu meningkatkan performa klasifikasi dan mengurangi jumlah kesalahan prediksi pada data pengujian. Dengan demikian, pendekatan *Hybrid MobileNetV3-SVM* dapat digunakan sebagai metode klasifikasi kondisi daun jeruk berbasis citra digital dengan tingkat akurasi yang tinggi.

Kata Kunci: Deep Learning; Klasifikasi Citra; Klasifikasi Kondisi Daun Jeruk; *MobileNetV3-Small*; Support Vector Machine.

1. PENDAHULUAN

Tanaman jeruk (*Citrus spp.*) merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi dan berperan penting dalam sektor pertanian di berbagai negara, termasuk Indonesia. Komoditas ini tidak hanya menjadi sumber pendapatan bagi petani, tetapi juga mendukung kebutuhan pangan dan industri olahan berbasis buah jeruk (Putra et al., 2024). Dalam proses pertumbuhannya, kondisi kesehatan tanaman menjadi faktor utama yang menentukan kualitas dan kuantitas hasil panen. Daun memiliki peranan penting karena

berfungsi sebagai pusat fotosintesis dan metabolisme tanaman. Oleh sebab itu, kerusakan atau gangguan pada daun dapat berdampak langsung terhadap produktivitas tanaman jeruk secara keseluruhan.

Berbagai gangguan pada daun jeruk dapat disebabkan oleh faktor patogen maupun nonpatogen. Kondisi seperti *citrus canker* dan *huanglongbing* (*Citrus Greening*) termasuk ancaman serius bagi budidaya jeruk karena mampu menurunkan kualitas tanaman secara signifikan. Selain itu, kondisi nonpatogen seperti defisiensi unsur hara juga sering memunculkan gejala *yellow leaves* yang mengganggu proses fisiologis tanaman (Bové, 2006; Gottwald, 2010). Gejala antar kondisi tersebut sering kali tampak serupa, terutama pada perubahan warna daun yang menunjukkan klorosis. Kesamaan visual inilah yang menyebabkan proses identifikasi di lapangan menjadi cukup sulit dilakukan secara konsisten.

Singerman dan Useche (2016) melaporkan bahwa kondisi *huanglongbing* menyebabkan penurunan hasil panen jeruk hingga sekitar 41% di Florida, Amerika Serikat. Angka tersebut menunjukkan bahwa kondisi daun bukan hanya persoalan teknis budidaya, tetapi juga dapat memengaruhi stabilitas industri jeruk secara luas. Di tingkat petani, identifikasi kondisi daun masih banyak dilakukan secara manual melalui pengamatan visual. Cara ini memang praktis, namun hasil identifikasi sering dipengaruhi oleh pengalaman pengamat, kondisi pencahayaan, serta kemiripan gejala antar kondisi. Dalam beberapa kasus, kondisi *Citrus Greening* dan *Yellow Leaves* sulit dibedakan karena sama-sama menampilkan pola klorosis pada permukaan daun (Nurmadinah et al., 2025). Akibatnya, penanganan yang diberikan dapat menjadi kurang tepat.

Perkembangan teknologi *deep learning* memberikan peluang baru dalam proses identifikasi kondisi tanaman berbasis citra digital. Salah satu metode yang paling banyak digunakan adalah *Convolutional Neural Network* (CNN) karena mampu mempelajari pola visual secara otomatis langsung dari citra masukan tanpa memerlukan ekstraksi fitur manual (LeCun et al., 2015). Pendekatan ini dinilai lebih efisien dan mampu menghasilkan performa klasifikasi yang tinggi pada berbagai penelitian pengenalan citra tanaman. Selain itu, penerapan *transfer learning* memungkinkan model memanfaatkan pengetahuan dari dataset berskala besar seperti *ImageNet* sehingga proses pelatihan menjadi lebih cepat dan efektif, terutama ketika jumlah data penelitian relatif terbatas (Pan & Yang, 2010).

Meskipun memiliki performa yang baik, penggunaan CNN sebagai model tunggal masih menghadapi beberapa kendala, khususnya pada dataset dengan distribusi kelas yang tidak seimbang. Pada kondisi tersebut, model cenderung lebih mudah mempelajari pola dari kelas mayoritas dibandingkan kelas minoritas. Dampaknya, performa klasifikasi pada kelas

dengan jumlah data sedikit sering mengalami penurunan. Permasalahan ini juga ditemukan pada dataset penelitian yang digunakan, di mana jumlah citra kelas *Spiny Whitefly* mencapai 672 citra, sedangkan kelas *Citrus Greening* hanya terdiri dari 254 citra. Rasio ketidakseimbangan sebesar 2,65:1 tersebut berpotensi menyebabkan bias prediksi dan menurunkan nilai *recall* maupun *F1-score* pada kelas minoritas (Kaur et al., 2024). Padahal, kelas-kelas minoritas tersebut justru penting untuk dideteksi secara akurat karena berkaitan dengan kondisi penyakit kritis pada tanaman.

Untuk mengatasi keterbatasan tersebut, beberapa penelitian mulai mengombinasikan CNN dengan *Support Vector Machine* (SVM) dalam skema *hybrid*. Pada pendekatan ini, CNN digunakan sebagai ekstraktor fitur untuk menghasilkan representasi visual berdimensi tinggi, sedangkan proses klasifikasi akhir dilakukan oleh SVM. Penggunaan SVM dinilai mampu meningkatkan kemampuan pemisahan antar kelas karena bekerja dengan prinsip *margin maximization* pada ruang fitur (Cervantes et al., 2020). Pendekatan tersebut dianggap lebih stabil ketika menghadapi data dengan distribusi yang tidak seimbang dibandingkan klasifikasi berbasis *softmax* pada CNN konvensional. Sejumlah penelitian sebelumnya, seperti yang dilakukan oleh Kaur et al. (2024), Banerjee et al. (2024), Banerjee et al. (2023), serta Al-Karawi dan Koyuncu (2024), juga menunjukkan bahwa model *hybrid* CNN-SVM mampu memberikan performa yang lebih baik dibandingkan CNN murni pada kasus klasifikasi kondisi tanaman.

Namun demikian, penelitian yang secara khusus membahas penerapan *hybrid MobileNetV3-SVM* pada klasifikasi kondisi daun jeruk dengan jumlah kelas yang banyak masih relatif terbatas. Sebagian besar penelitian sebelumnya hanya berfokus pada sedikit kelas penyakit atau belum mempertimbangkan permasalahan ketidakseimbangan data secara mendalam. Selain itu, analisis mengenai pengaruh strategi *random under sampling* terhadap performa kelas minoritas juga masih jarang dibahas secara komprehensif. Kondisi tersebut menunjukkan bahwa masih terdapat ruang penelitian yang dapat dikembangkan, khususnya pada implementasi *MobileNetV3* yang dikombinasikan dengan SVM pada dataset *multi-class* dengan distribusi data yang tidak merata.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model *hybrid MobileNetV3-SVM* dalam klasifikasi sebelas kelas kondisi daun jeruk berbasis citra digital menggunakan dataset publik Mendeley yang terdiri dari 5.813 citra. Penelitian ini difokuskan pada evaluasi performa model dalam menangani distribusi kelas yang tidak seimbang melalui penerapan teknik *Random Under Sampling* (RUS) pada data pelatihan. Selain itu, penelitian ini juga membandingkan performa model *hybrid* dengan CNN murni sebagai *baseline* untuk mengetahui sejauh mana kontribusi penggunaan SVM terhadap

peningkatan hasil klasifikasi. Diharapkan hasil penelitian ini dapat memberikan kontribusi dalam pengembangan sistem deteksi penyakit tanaman jeruk yang lebih akurat dan efisien untuk mendukung sektor pertanian berbasis teknologi cerdas.

2. TINJAUAN PUSTAKA

Tanaman Jeruk

Tanaman jeruk (*Citrus spp.*) merupakan komoditas hortikultura bernilai ekonomi tinggi yang keberhasilan budidayanya sangat dipengaruhi oleh kondisi fisiologis tanaman, khususnya pada bagian daun yang berperan penting dalam proses fotosintesis. Dalam literatur pertanian dan fitopatologi jeruk, berbagai gangguan pada tanaman jeruk dijelaskan berdasarkan karakteristik visual yang muncul pada daun. *Citrus canker* dilaporkan menimbulkan lesi nekrotik berbentuk bercak dengan tepi kekuningan, sedangkan *huanglongbing* (HLB) atau citrus greening ditandai dengan klorosis tidak merata (blotchy mottling) serta perubahan warna dan bentuk daun. Selain itu, kondisi daun jeruk juga dapat dipengaruhi oleh aktivitas hama seperti mealybugs dan spiny whitefly yang menyebabkan kerusakan jaringan serta perubahan tekstur permukaan daun. Kondisi visual lain yang umum dijumpai meliputi daun menguning (*yellow leaves*), kerusakan jaringan daun (*foliage damaged*), bercak lubang (*shot hole*), *powdery mildew*, dan *die back*, yang masing-masing menunjukkan karakteristik visual berbeda pada daun jeruk. Kajian fitopatologi jeruk menunjukkan bahwa *huanglongbing* merupakan salah satu gangguan paling merusak pada tanaman jeruk, dengan gejala visual khas pada daun seperti klorosis tidak simetris, perubahan warna, dan deformasi permukaan daun. Gejala visual tersebut sering dimanfaatkan sebagai dasar identifikasi awal kondisi daun jeruk melalui pengamatan visual di lapangan. Meskipun *huanglongbing* secara biologis diklasifikasikan sebagai kondisi yang disebabkan oleh bakteri *Candidatus Liberibacter* dan ditularkan oleh serangga vektor, dalam konteks penelitian berbasis citra digital, gejala-gejala tersebut diperlakukan sebagai kondisi visual daun. Pendekatan ini tidak bertujuan untuk melakukan diagnosis fitopatologis secara langsung, melainkan untuk mengklasifikasikan kondisi daun jeruk berdasarkan pola visual sebagaimana dijelaskan dalam literatur pertanian dan fitopatologi jeruk (Wang et al., 2017; Sadamo, 2023).

Pengolahan Citra Digital

Pengolahan Citra Digital didefinisikan sebagai disiplin ilmu yang mempelajari teknik pengolahan gambar. Gambar yang dimaksud dapat berupa foto maupun citra bergerak (dari webcam). Secara matematis, citra dapat dipandang sebagai fungsi dua dimensi $f(x,y)$, di mana x dan y merupakan koordinat spasial pada bidang datar, sedangkan nilai f pada koordinat

tersebut merepresentasikan intensitas atau tingkat keabuan. Sebuah citra digital dapat direpresentasikan sebagai matriks dua dimensi berukuran $N \times M$. Setiap elemen matriks $f(x,y)$ menyatakan nilai intensitas piksel pada koordinat baris x dan kolom y . Parameter N menunjukkan jumlah baris citra, sedangkan M menunjukkan jumlah kolom citra. Representasi tersebut dituliskan dalam bentuk matriks numerik sebagai berikut:

$$f(x,y) \approx f(x,y) \approx \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,M-1) \\ f(1,0) & f(1,1) & \dots & f(1,M-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(N-1,0) & f(N-1,1) & \dots & f(N-1,M-1) \end{bmatrix} \quad (i)$$

Suatu citra $f(x,y)$ dalam fungsi matematis dapat dituliskan sebagai berikut:

$$0 \leq x \leq M-1$$

$$0 \leq y \leq N-1$$

$$0 \leq f(x,y) \leq G-1$$

Keterangan:

M = jumlah piksel baris pada array citra

N = jumlah piksel kolom pada array citra

G = nilai skala tingkat keabuan

Nilai M , N , dan G umumnya merupakan bilangan berpangkat dua: $M = 2^m$, $N = 2^n$, $G = 2^k$

dengan m , n , dan k merupakan bilangan bulat positif. Interval $(0,G)$ disebut grayscale. Besarnya nilai G bergantung pada proses digitalisasi. Umumnya tingkat keabuan 0 (nol) merepresentasikan intensitas hitam dan 1 (satu) merepresentasikan intensitas putih. Pada citra 8-bit, nilai G sama dengan: $G = 2^8 = 256$ warna (tingkat keabuan) (Simangunsong et al., 2025)

Deep Learning

Deep Learning merupakan subbidang dari *machine learning* yang dikembangkan berdasarkan struktur *Artificial Neural Network* dengan banyak *hidden layer*. Keunggulan utama metode ini terletak pada kemampuannya melakukan ekstraksi fitur otomatis (*automatic feature learning*) langsung dari data mentah tanpa memerlukan intervensi manusia dalam proses rekayasa fitur manual (Yuliany et al., 2022).

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan jenis neural network yang umum digunakan untuk menganalisis data citra. CNN sangat efektif dalam mendeteksi dan mengenali objek gambar karena dirancang khusus untuk memproses data dengan struktur topologi grid.

CNN pertama kali diperkenalkan pada tahun 1960-an dan menunjukkan hasil yang menjanjikan dalam bidang computer vision. Secara teknis, CNN merupakan arsitektur yang dapat dilatih (*trainable architecture*) dan terdiri dari beberapa tahapan. CNN merupakan kombinasi antara konvolusi citra yang berfungsi untuk proses ekstraksi fitur dan neural network yang berfungsi untuk klasifikasi. Berdasarkan arsitektur LeNet5, terdapat empat jenis lapisan utama pada CNN yaitu convolutional layer, ReLU layer, pooling layer, dan fully connected layer.

MobileNetV3

MobileNetV3 merupakan generasi ketiga arsitektur CNN yang dikembangkan oleh Google dengan fokus utama pada efisiensi komputasi pada perangkat mobile dan sistem tertanam. Pengembangan *MobileNetV3* memanfaatkan dua teknik utama yaitu *Platform-Aware Neural Architecture Search* (NAS) untuk menemukan struktur jaringan global yang optimal dengan menyeimbangkan akurasi dan latensi, serta algoritma NetAdapt untuk melakukan fine-tuning pada setiap lapisan. Selain itu, penggunaan fungsi aktivasi non-linear hard swish (h-swish) dan optimasi pada lapisan awal serta akhir menghasilkan keseimbangan terbaik antara performa dan kecepatan pada perangkat dengan sumber daya CPU terbatas.

MobileNetV3-Small

MobileNetV3-Small dikembangkan khusus untuk perangkat dengan keterbatasan sumber daya melalui arsitektur yang lebih ringkas. Model ini memiliki beban komputasi yang lebih ringan dibandingkan varian *Large*, dengan *expansion size* maksimal sebesar 576 dan *output channel* sebanyak 1.024 sebelum tahap klasifikasi. Efisiensi representasi pada model kecil ini dioptimalkan melalui penerapan modul *Squeeze-and-Excitation* di hampir seluruh lapisan, serta penggunaan aktivasi *h-swish* yang lebih ekstensif sejak lapisan awal. Secara performa, *MobileNetV3-Small* mampu mencapai akurasi 67,5% dengan hanya mengandalkan 2,5 juta parameter, yang berarti terdapat peningkatan akurasi sebesar 6,6% dibandingkan *MobileNetV2* pada tingkat latensi yang setara Transfer Learning.

Transfer learning merupakan metode menggunakan kembali model yang telah dilatih secara menyeluruh pada dataset besar. Tujuannya menerapkan pengetahuan yang sudah didapat tersebut ke dataset yang lebih kecil, dengan hanya melatih ulang lapisan terakhir model untuk adaptasi pada tugas klasifikasi baru, sementara lapisan fitur awal dipertahankan (Simangunsong et al., 2025)

Optimizer Adam

Optimizer Adam bekerja dengan menghitung momentum orde pertama (nilai rata-rata gradien) dan momentum orde kedua (variansi gradien yang tidak dipusatkan) pada setiap iterasi pelatihan. Model kemudian memanfaatkan kedua estimasi momentum tersebut untuk

menghasilkan learning rate adaptif pada setiap parameter model sehingga memungkinkan konvergensi yang lebih cepat dan stabil selama proses pelatihan. Berikut merupakan rumus optimizer Adam:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad [\text{ii}]$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad [\text{iii}]$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad [\text{iv}]$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad [\text{v}]$$

$$\theta_{t+1} = \theta_t - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad [\text{vi}]$$

optimizer Adam menggerakkan parameter (θ) menuju solusi optimal dengan laju pembaruan (α). Keputusan pembaruan ini dipandu oleh gradien saat ini (g_t) dan dua nilai historis. m_t adalah rata-rata pergerakan gradien, v_t adalah varian pergerakan gradien, parameter β_1 dan β_2 menentukan bobot memori dari riwayat momen (m_t dan v_t), dan ϵ adalah nilai minimal yang di sisipkan untuk mencegah operasi pembagian menjadi tidak terdefinisi (Asy Syifa & Amelia Dewi, 2022).

Support Vector Machine

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin *supervised* yang dikembangkan berdasarkan teori *Structural Risk Minimization* (SRM). SVM mencari *hyperplane* pemisah optimal yang memaksimalkan margin antara kelas-kelas data dalam ruang fitur, di mana sampel yang berada paling dekat dengan *hyperplane* disebut sebagai *support vectors* (Cervantes et al., 2020). Untuk permasalahan klasifikasi nonlinear, SVM memanfaatkan fungsi kernel untuk memetakan data dari ruang fitur asli ke ruang dimensi yang lebih tinggi, tempat batas keputusan linear menjadi mungkin ditentukan. Kernel *Radial Basis Function* (RBF) dengan persamaan $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ merupakan pilihan yang paling umum karena kemampuannya menangani hubungan nonlinear kompleks pada data berdimensi tinggi.

Dalam konteks klasifikasi multikelas seperti pada penelitian ini dengan sebelas kelas kondisi daun, SVM menggunakan strategi *one-versus-one* (OvO) yang membangun sebanyak $k(k-1)/2 = 55$ pengklasifikasi biner untuk sebelas kelas, kemudian mengagregasi keputusan melalui skema pemungutan suara. Strategi *class weighting balanced* yang diimplementasikan dalam penelitian ini menyesuaikan bobot penalti C untuk setiap kelas secara proporsional terhadap invers frekuensi kemunculannya, sehingga kelas-kelas minoritas memperoleh bobot

penalti yang lebih tinggi dan model tidak bias terhadap kelas mayoritas dalam menentukan *hyperplane* optimal.

Undersampling

Random Under Sampling (RUS) adalah salah satu metode undersampling yang mengurangi jumlah sampel pada kelas mayoritas dengan menghapus sebagian data secara acak. Metode ini akan membuang dataset dari kelas mayoritas pada data latih sehingga jumlah data kelas mayoritas berkurang. Kekurangan dari teknik ini adalah kemungkinan terhapusnya data yang sebenarnya penting dalam pembangunan model klasifikasi (Budi Utomo et al., 2024).

3. METODE PENELITIAN

Penelitian ini merupakan penelitian eksperimen yang bertujuan mengembangkan model klasifikasi kondisi daun jeruk berbasis citra digital menggunakan pendekatan hibrida *MobileNetV3-Small* dan *Support Vector Machine* (SVM). Penelitian memanfaatkan *Multi-format Open-Source Sweet Orange Leaf Disease Dataset Version 1* yang diperoleh dari *Mendeley Data*, berisi 5.813 citra daun jeruk yang dikumpulkan di wilayah Khemerdia, Bheramara, Kushtia, Bangladesh pada 19–22 Agustus 2023. Populasi penelitian adalah seluruh citra daun jeruk dalam dataset, sedangkan sampel penelitian berupa 5.813 citra yang terdiri atas sebelas kategori kondisi daun jeruk. Instrumen penelitian berupa dataset citra digital, model *MobileNetV3-Small* sebagai ekstraktor fitur, dan SVM kernel *Radial Basis Function* (RBF) sebagai pengklasifikasi. Teknik pengumpulan data dilakukan melalui pemanfaatan dataset sekunder yang tersedia secara terbuka, kemudian citra dipraproses dengan mengubah ukuran menjadi 224×224 piksel dan dibagi menggunakan *stratified split* dengan rasio 70% data pelatihan, 15% data validasi, dan 15% data pengujian. Untuk mengatasi ketidakseimbangan kelas pada data pelatihan, diterapkan metode *Random Under Sampling* (RUS). Teknik analisis data dilakukan melalui pelatihan model menggunakan *transfer learning* dan *fine-tuning*, dilanjutkan dengan evaluasi performa menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-score* guna menilai kemampuan model dalam mengklasifikasikan sebelas kategori kondisi daun jeruk.

4. HASIL DAN PEMBAHASAN


Perancangan Model Hybrid *MobileNetV3*-SVM

Model yang dikembangkan dalam penelitian ini menggunakan pendekatan Hybrid *MobileNetV3*-SVM untuk mengklasifikasikan sebelas kategori kondisi daun jeruk berdasarkan citra digital. *MobileNetV3*-Small digunakan sebagai ekstraktor fitur karena memiliki jumlah parameter yang relatif ringan namun mampu menghasilkan representasi fitur visual yang baik. Sebelum proses pelatihan dilakukan, seluruh citra diubah ukurannya menjadi 224×224 piksel dan diproses menggunakan fungsi preprocessing bawaan *MobileNetV3*. Proses pembelajaran fitur memanfaatkan transfer learning dengan bobot awal dari ImageNet, kemudian dilanjutkan dengan fine-tuning pada beberapa lapisan akhir jaringan agar model dapat menyesuaikan diri dengan karakteristik visual penyakit daun jeruk.

Berbeda dengan *MobileNetV3*-Small murni yang menggunakan Softmax sebagai classifier, penelitian ini memanfaatkan fitur yang dihasilkan oleh Dense Layer sebagai masukan bagi Support Vector Machine (SVM). SVM dipilih karena mampu melakukan klasifikasi secara efektif pada ruang fitur berdimensi tinggi hasil ekstraksi CNN. Pada penelitian ini digunakan kernel Radial Basis Function (RBF) dengan parameter C sebesar 100 karena mampu menangani pemisahan data yang tidak sepenuhnya bersifat linear. Alur kerja model dimulai dari proses input citra, preprocessing, ekstraksi fitur menggunakan *MobileNetV3*-Small, pembentukan vektor fitur, klasifikasi menggunakan SVM, hingga menghasilkan prediksi kelas kondisi daun jeruk. Kombinasi kedua metode tersebut diharapkan mampu meningkatkan kemampuan klasifikasi dibandingkan penggunaan *MobileNetV3*-Small murni.


Hasil Pengujian Model dengan Hybrid *MobileNetV3*-SVM

Pengujian dilakukan menggunakan 878 citra pada data pengujian yang tidak digunakan pada tahap pelatihan maupun validasi. Evaluasi ini bertujuan untuk mengukur kemampuan model dalam mengidentifikasi sebelas kategori kondisi daun jeruk berdasarkan citra digital. Model yang diuji merupakan kombinasi *MobileNetV3*-Small sebagai ekstraktor fitur dan Support Vector Machine (SVM) kernel RBF sebagai pengklasifikasi.



Gambar 1. Grafik Support Data Hybrid *MobileNetV3*-SVM.

Berdasarkan Gambar 1, jumlah sampel pada setiap kelas pengujian mengikuti distribusi dataset asli. Kelas *Spiny Whitefly* memiliki jumlah sampel terbanyak, sedangkan *Citrus Greening* memiliki jumlah sampel paling sedikit. Distribusi tersebut menunjukkan bahwa proses evaluasi dilakukan pada data yang mempertahankan proporsi kelas sebagaimana terdapat pada dataset, sehingga hasil pengujian mencerminkan kinerja model pada kondisi data yang digunakan dalam penelitian.



Gambar 2. Confusion matrix Hybrid MobileNetV3-SVM.

Confusion matrix pada Gambar 2 memperlihatkan bahwa sebagian besar hasil prediksi berada pada diagonal utama matriks. Kondisi ini menunjukkan tingkat kesesuaian yang tinggi antara hasil prediksi dan label aktual. Dari 878 citra yang diuji, sebanyak 862 citra berhasil diklasifikasikan sesuai kelasnya, sedangkan 16 citra lainnya mengalami kesalahan klasifikasi. Seluruh sampel pada kelas *Citrus Mealybugs*, *Healthy Leaf*, *Shot hole*, dan *Spiny Whitefly* berhasil dikenali dengan benar. Kesalahan prediksi hanya ditemukan pada sebagian kecil sampel yang tersebar pada beberapa kategori, sehingga tidak memengaruhi pola performa model secara keseluruhan.

=== HASIL HYBRID CNN-SVM ===

	precision	recall	f1-score	support
Citrus canker	0.9556	0.9663	0.9609	89
Citrus greening	0.9500	0.9744	0.9620	39
Citrus mealybugs	1.0000	1.0000	1.0000	91
Die back	0.9897	0.9897	0.9897	97
Foliage damaged	1.0000	0.9474	0.9730	95
Healthy leaf	0.9881	1.0000	0.9940	83
Powdery mildew	0.9670	0.9778	0.9724	90
Shot hole	1.0000	1.0000	1.0000	84
Spiny whitefly	1.0000	1.0000	1.0000	101
Yellow dragon	0.9365	0.9516	0.9440	62
Yellow leaves	0.9787	0.9787	0.9787	47
accuracy			0.9818	878
macro avg	0.9787	0.9805	0.9795	878
weighted avg	0.9820	0.9818	0.9818	878

Gambar 3. Classification Report Hybrid MobileNetV3-SVM.

Berdasarkan Gambar 3, seluruh kelas memperoleh nilai precision, recall, dan F1-score di atas 94%. Kelas *Citrus Mealybugs*, *Shot hole*, dan *Spiny Whitefly* memperoleh nilai precision, recall, dan F1-score sebesar 100%, yang menunjukkan bahwa seluruh sampel pada ketiga kategori tersebut berhasil diklasifikasikan sesuai label aktual. Nilai F1-score terendah diperoleh oleh kelas *Yellow Dragon* sebesar 94,40%, sedangkan kelas lainnya berada pada


rentang nilai yang relatif tinggi. Hasil tersebut menunjukkan bahwa model mampu mempertahankan performa klasifikasi yang konsisten pada seluruh kategori yang diuji.

Selain evaluasi pada masing-masing kelas, nilai weighted average menghasilkan precision sebesar 98,20%, recall sebesar 98,18%, dan F1-score sebesar 98,18%, sedangkan macro average F1-score mencapai 97,95%. Nilai tersebut menunjukkan bahwa performa model tetap tinggi baik ketika memperhitungkan proporsi jumlah sampel setiap kelas maupun ketika seluruh kelas dievaluasi secara setara.

Secara keseluruhan, model Hybrid *MobileNetV3*-SVM memperoleh akurasi sebesar 98,18%, precision sebesar 98,20%, recall sebesar 98,18%, dan F1-score sebesar 98,18%. Hasil tersebut menunjukkan bahwa kombinasi *MobileNetV3*-Small dan SVM kernel RBF mampu menghasilkan kinerja klasifikasi yang tinggi pada sebelas kategori kondisi daun jeruk. Dominasi nilai pada diagonal utama *Confusion matrix* serta tingginya nilai evaluasi pada hampir seluruh kelas menunjukkan bahwa model dapat melakukan proses klasifikasi secara akurat dan konsisten pada data pengujian yang digunakan dalam penelitian ini.

Hasil Pengujian Model dengan *MobileNetV3* Murni


Pengujian model dilakukan menggunakan 878 citra pada data pengujian yang tidak terlibat dalam proses pelatihan maupun validasi. Evaluasi dilakukan untuk mengukur kemampuan *MobileNetV3*-Small dalam mengklasifikasikan sebelas kategori penyakit dan kondisi daun jeruk berdasarkan citra digital. Berbeda dengan model hybrid, proses klasifikasi pada model ini dilakukan secara langsung menggunakan lapisan Softmax yang terdapat pada arsitektur *MobileNetV3*-Small.



Gambar 4. Grafik Support Data *MobileNetV3*-Small.

Berdasarkan Gambar 4, jumlah sampel pada setiap kelas pengujian mengikuti distribusi asli dataset. Kelas *Spiny Whitefly* memiliki jumlah sampel terbanyak, sedangkan *Citrus Greening* memiliki jumlah sampel paling sedikit. Distribusi tersebut menunjukkan bahwa evaluasi dilakukan menggunakan data yang mempertahankan proporsi setiap kelas

sebagaimana terdapat pada dataset penelitian sehingga hasil pengujian mencerminkan kemampuan model pada kondisi data yang digunakan dalam penelitian.



Gambar 5. Confusion matrix MobileNetV3-Small.

Berdasarkan Gambar 5, sebagian besar hasil prediksi berada pada diagonal utama *Confusion matrix* yang menunjukkan kesesuaian antara hasil prediksi dan label aktual. Dari total 878 citra pengujian, sebanyak 854 citra berhasil diklasifikasikan dengan benar, sedangkan 24 citra mengalami kesalahan klasifikasi. Jumlah kesalahan tersebut menunjukkan bahwa mayoritas citra pada data pengujian dapat dikenali sesuai dengan kelasnya. Kesalahan prediksi hanya ditemukan pada sebagian kecil sampel yang tersebar pada beberapa kategori, sehingga secara umum model mampu melakukan klasifikasi dengan baik pada seluruh kelas yang diuji.

=== METRIK PER CLASS ===

	Class	Precision	Recall	F1-Score	Support
0	Citrus canker	1.000000	0.887640	0.940476	89
1	Citrus greening	1.000000	0.974359	0.987013	39
2	Citrus mealybugs	1.000000	0.989011	0.994475	91
3	Die back	0.969697	0.989691	0.979592	97
4	Foliage damaged	0.958333	0.968421	0.963351	95
5	Healthy leaf	0.965116	1.000000	0.982249	83
6	Powdery mildew	0.945652	0.966667	0.956044	90
7	Shot hole	0.976190	0.976190	0.976190	84
8	Spiny whitefly	0.980583	1.000000	0.990196	101
9	Yellow dragon	0.953846	1.000000	0.976378	62
10	Yellow leaves	0.956522	0.936170	0.946237	47

Gambar 6. Classification Report MobileNetV3-Small.

Berdasarkan Gambar 6, seluruh kategori memperoleh nilai precision, recall, dan F1-score di atas 94%. Kelas *Citrus Mealybugs* memperoleh nilai F1-score tertinggi sebesar 99,45%, sedangkan kelas *Citrus canker* memperoleh nilai F1-score sebesar 94,05%. Hasil tersebut menunjukkan bahwa model mampu mempertahankan performa klasifikasi yang tinggi pada seluruh kategori penyakit daun jeruk yang diuji. Selain evaluasi per kelas, nilai weighted average menghasilkan precision sebesar 97,32%, recall sebesar 97,27%, dan F1-score sebesar 97,25%. Nilai tersebut menunjukkan bahwa performa model tetap tinggi setelah mempertimbangkan proporsi jumlah sampel pada setiap kelas. Secara keseluruhan, hasil pengujian menunjukkan bahwa model *MobileNetV3-Small* murni memperoleh akurasi sebesar 97,27%. Dominasi nilai pada diagonal utama *Confusion matrix* serta tingginya nilai evaluasi

pada hampir seluruh kelas menunjukkan bahwa model mampu menghasilkan performa klasifikasi yang konsisten

Perbandingan antara Hybrid *MobileNetV3*-SVM dan *MobileNetV3* Murni

Perbandingan dilakukan untuk mengetahui pengaruh penggunaan Support Vector Machine (SVM) sebagai classifier terhadap performa *MobileNetV3*-Small dalam klasifikasi kondisi daun jeruk. Kedua model diuji menggunakan data pengujian yang sama, yaitu 878 citra, sehingga hasil evaluasi dapat dibandingkan secara langsung pada kondisi yang setara. Perbedaan utama kedua model terletak pada tahap klasifikasi, di mana *MobileNetV3*-Small murni menggunakan lapisan Softmax, sedangkan model hybrid memanfaatkan fitur hasil ekstraksi *MobileNetV3*-Small yang kemudian diklasifikasikan menggunakan SVM kernel RBF.

Tabel 1. Perbandingan Evaluasi Kedua Model.

Metrik	<i>MobileNetV3</i> -Small	Hybrid <i>MobileNetV3</i> -SVM
Accuracy	97,27%	98,18%
Precision	97,32%	98,20%
Recall	97,27%	98,18%
F1-Score	97,25%	98,18%

Berdasarkan Tabel 1, model Hybrid *MobileNetV3*-SVM menunjukkan performa yang lebih tinggi dibandingkan *MobileNetV3*-Small murni pada seluruh metrik evaluasi. Akurasi meningkat dari 97,27% menjadi 98,18%, sedangkan precision, recall, dan F1-score juga mengalami peningkatan. Selain itu, jumlah kesalahan klasifikasi berkurang dari 24 citra pada *MobileNetV3*-Small murni menjadi 16 citra pada model hybrid dari total 878 citra pengujian.

Meskipun peningkatan akurasi yang diperoleh sebesar 0,91%, hasil tersebut menunjukkan adanya perbaikan dalam kemampuan model untuk membedakan kategori kondisi daun jeruk. Berkurangnya jumlah kesalahan prediksi menunjukkan bahwa fitur yang dihasilkan oleh *MobileNetV3*-Small dapat dimanfaatkan secara lebih efektif ketika proses klasifikasi dilakukan menggunakan SVM kernel RBF dibandingkan dengan penggunaan lapisan Softmax secara langsung. Secara keseluruhan, hasil perbandingan menunjukkan bahwa pendekatan Hybrid *MobileNetV3*-SVM memberikan kinerja yang lebih baik dibandingkan *MobileNetV3*-Small murni pada dataset yang digunakan dalam penelitian ini. Peningkatan yang diperoleh terlihat pada seluruh metrik evaluasi serta pada penurunan jumlah kesalahan klasifikasi selama proses pengujian.

5. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi kondisi daun jeruk menggunakan pendekatan Hybrid *MobileNetV3*-SVM dan *MobileNetV3*-Small murni pada sebelas kategori kondisi daun jeruk. *MobileNetV3*-Small digunakan sebagai ekstraktor fitur melalui transfer learning dan fine-tuning, sedangkan pada model hybrid proses klasifikasi dilakukan menggunakan Support Vector Machine (SVM) kernel RBF. Pengujian dilakukan menggunakan data yang tidak terlibat dalam proses pelatihan maupun validasi sehingga hasil evaluasi dapat menggambarkan kemampuan model dalam melakukan klasifikasi pada data baru.

Hasil pengujian menunjukkan bahwa model Hybrid *MobileNetV3*-SVM memperoleh akurasi sebesar 98,18%, precision sebesar 98,20%, recall sebesar 98,18%, dan F1-score sebesar 98,18%, sedangkan *MobileNetV3*-Small murni memperoleh akurasi sebesar 97,27%, precision sebesar 97,32%, recall sebesar 97,27%, dan F1-score sebesar 97,25%. Selain menghasilkan nilai evaluasi yang lebih tinggi pada seluruh metrik, model hybrid juga mampu mengurangi jumlah kesalahan klasifikasi dari 24 citra menjadi 16 citra pada 878 citra pengujian.

Berdasarkan hasil yang diperoleh, pendekatan Hybrid *MobileNetV3*-SVM memberikan kinerja yang lebih baik dibandingkan *MobileNetV3*-Small murni pada dataset yang digunakan dalam penelitian ini. Integrasi *MobileNetV3*-Small sebagai ekstraktor fitur dan SVM kernel RBF sebagai classifier mampu meningkatkan kemampuan model dalam membedakan kategori kondisi daun jeruk sehingga menghasilkan performa klasifikasi yang lebih tinggi dan lebih konsisten pada data pengujian.

DAFTAR PUSTAKA

- Al-Karawi, S. B. H., & Koyuncu, H. (2024). Hybrid neural network approach for tea leaf disease detection using Pelican and Mayfly optimization algorithms. *Jurnal Riset Informatika*, 6(2), 119–130. <https://doi.org/10.34288/jri.v6i2.274>
- Asy Syifa, S., & Amelia Dewi, I. (2022). MIND (Multimedia Artificial Intelligent Networking Database): Arsitektur ResNet-152 dengan perbandingan optimizer Adam dan RMSProp untuk mendeteksi penyakit paru-paru. *MIND Journal*, 7(2), 139–150. <https://doi.org/10.26760/mindjournal.v7i2.139-150>
- Banerjee, D., Kukreja, V., Gupta, A., Singh, V., & Brar, T. P. S. (2023). Combining CNN and SVM for accurate identification of ridge gourd leaf diseases. In *Proceedings of the 2023 3rd Asian Conference on Innovation in Technology (ASIANCON)* (pp. 1–5). IEEE. <https://doi.org/10.1109/ASIANCON58793.2023.10269834>
- Banerjee, D., Kukreja, V., Srivastava, P., Bhattacharjee, A., & Joshi, K. (2024). Enhancing rice leaf disease classification: A CNN-SVM approach. In *Proceedings of the 2024 International Conference on Emerging Smart Computing and Informatics (ESCI)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ESCI59607.2024>

- Bové, J. M. (2006). Huanglongbing: A destructive, newly emerging, century-old disease of citrus. *Journal of Plant Pathology*, 88(1), 7–37. <https://doi.org/10.4454/jpp.v88i1.828>
- Budi Utomo, P., Faruqziddan, M., Herdika Septa Aulia, E., & Dini Azzahra, S. (2024). Perbandingan skenario balancing oversampling dan undersampling dalam klasifikasi risiko kambuh kanker tiroid menggunakan algoritma SVM linear. *JAMI: Jurnal Ahli Muda Indonesia*, 5(2), 172–182. <https://doi.org/10.46510/jami.v5i2.320>
- Cervantes, J., García-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189–215. <https://doi.org/10.1016/j.neucom.2019.10.118>
- Gottwald, T. R. (2010). Current epidemiological understanding of citrus huanglongbing. *Annual Review of Phytopathology*, 48, 119–139. <https://doi.org/10.1146/annurev-phyto-073009-114418>
- Howard, A., Sandler, M., Chen, B., Wang, W., Chen, L.-C., Tan, M., Chu, G., Vasudevan, V., Zhu, Y., Pang, R., Adam, H., & Le, Q. (2019). Searching for MobileNetV3. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)* (pp. 1314–1324). <https://doi.org/10.1109/ICCV.2019.00140>
- Kaur, P., Mishra, A. M., Goyal, N., Gupta, S. K., Shankar, A., & Viriyasitavat, W. (2024). A novel hybrid CNN methodology for automated leaf disease detection and classification. *Expert Systems*, 41(7), e13543. <https://doi.org/10.1111/exsy.13543>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Nurmadinah, N., Hasanuddin, A., & Ramli, M. (2025). Classification of leaf disease using GLCM and SVM. *Jurnal Teknik Informatika*, 13(1), 44–52. <https://doi.org/10.30872/jti.v13i1.9215>
- Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
- Putra, A. R., Nugraha, D., & Hidayat, S. (2024). Image-based plant disease detection using CNN. *Jurnal Informatika dan Sistem Informasi*, 10(1), 77–85. <https://doi.org/10.28932/jisi.v10i1.6521>
- Sadamo, S. C. (2023). Status and significance of citrus greening (Huanglongbing) disease in Ethiopia. *Plant*, 11(3), 67–75. <https://doi.org/10.11648/j.plant.20231103.14>
- Simangunsong, J., Simanjuntak, N. D., & Matondang, A. A. (2025). Penerapan transfer learning untuk klasifikasi citra bunga berbasis convolutional neural network. *Jurnal Minfo Polgan*, 14(1), 1062–1067. <https://doi.org/10.33395/jmp.v14i1.14980>
- Singerman, A., & Useche, P. (2016). *Impact of citrus greening on citrus operations in Florida* (EDIS Publication FE983). University of Florida IFAS Extension. <https://edis.ifas.ufl.edu/publication/FE983>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>

Yuliany, S., Aradea, & Rachman, A. N. (2022). Implementasi deep learning pada sistem klasifikasi hama tanaman padi menggunakan metode convolutional neural network (CNN). *Jurnal Buana Informatika*, 13(1), 54–65.
<https://doi.org/10.24002/jbi.v13i1.5022>