JSAI : Journal Scientific and Applied Informatics
Vol. 09, No. 3, *October* 2026, *pages*. 409~415
E-ISSN: 2614-3054; P-ISSN: 2614-3062, *accredited by Kemenristekdikti*, Sinta 4
DOI: 10.36085

Klasifikasi Citra Bunga Tropis Berbasis MobileNetV2 Menggunakan Pendekatan Pengembangan Iteratif

[1]Noufal Maulana, [2]Hadi Zakaria
[1,2, 3]Fakultas Ilmu Komputer, Universitas Pamulang, Indonesia
[1]*noufalmaulana2003@gmail.com*; [2]*dosen00274@unpam.ac.id*

Article Info

Article history:

Received, 2026-10-15
Revised, 2026-10-24
Accepted, 2026-11-05

Kata Kunci:

bunga_tropis
convolutional_neural_network
early_stopping
klasifikasi_citra
mobilenetv2

ABSTRAK

Keanekaragaman spesies bunga tropis dan kemiripan morfologi visual antarkelas menjadi tantangan utama dalam proses identifikasi manual yang rentan terhadap ketidakakuratan. Penelitian ini bertujuan mengimplementasikan algoritma *Convolutional Neural Network* (CNN) berbasis arsitektur MobileNetV2 untuk mengotomatisasi klasifikasi citra bunga tropis menggunakan pendekatan model iteratif. Dataset yang digunakan terdiri dari 7.500 citra digital dari 15 kelas bunga tropis. Tahap *pra-pemrosesan* meliputi pengubahan ukuran citra, normalisasi, dan *augmentasi* data. Pemodelan dieksekusi menggunakan *framework* PyTorch dengan menerapkan fungsi *Early Stopping* dan *Learning Rate Scheduler*. Hasil evaluasi kuantitatif pada 1.125 data uji menunjukkan model MobileNetV2 berhasil mencapai akurasi sebesar 84,0%, *Precision* 84,0%, *Recall* 84,0%, dan *F1-Score* 83,0%. Hasil ini membuktikan bahwa MobileNetV2 efektif dan efisien dalam mengekstrak fitur visual spesifik flora tropis.

Keywords:

tropical_flower
convolutional_neural_network
early_stopping
image_classification
mobilenetv2

ABSTRACT

The diversity of tropical flower species and visual morphological similarities between classes pose significant challenges for manual identification, a process prone to inaccuracy. This study aims to implement a Convolutional Neural Network (CNN) algorithm based on the MobileNetV2 architecture to automate tropical flower image classification using an iterative modeling approach. The dataset comprises 7,500 digital images across 15 tropical flower classes. Pre-processing stages include image resizing, normalization, and data augmentation. Modeling was executed using the PyTorch framework, incorporating Early Stopping and a Learning Rate Scheduler. Quantitative evaluation on 1,125 test samples demonstrated that the MobileNetV2 model achieved an accuracy of 84.0%, precision of 84.0%, recall of 84.0%, and an F1-score of 83.0%. These results confirm the effectiveness and efficiency of MobileNetV2 in extracting specific visual features of tropical flora.

This is an open access article under the CC BY-SAlicense.

Penulis Korespondensi:

Hadi Zakaria,
Universitas Pamulang,
Email: *dosen00274@unpam.ac.id*

1. PENDAHULUAN

Identifikasi karakteristik fisik flora secara visual merupakan alur fundamental dalam domain taksonomi digital, botani terapan, dan pengenalan pola objek biologi [1]. Pemrosesan citra digital memungkinkan ekstraksi fitur visual berdimensi tinggi seperti pola morfologi mahkota bunga, sebaran spektrum warna, pola venasi daun, dan tekstur permukaan objek guna menentukan spesies tanaman secara otomatis tanpa merusak spesimen asli [2]. Wilayah beriklim tropis memiliki keanekaragaman flora yang sangat kaya, salah satunya ditandai oleh beragamnya spesies bunga hias yang bernilai ekologis dan ekonomis tinggi. Namun, tingkat variasi intra-class yang tinggi (seperti variasi sudut pengambilan gambar, intensitas pencahayaan alami, tahap mekar bunga, dan variasi kultivar) serta kemiripan antarspesies (high inter-class similarity) membuat permasalahan klasifikasi bunga tropis masuk ke dalam ranah *Fine-Grained Visual Classification* (FGVC) yang sangat kompleks [3], [4].

Pada praktik lapangannya, proses identifikasi jenis bunga tropis masih dominan dilakukan secara manual berbasis pengamatan visual langsung oleh tenaga ahli botani atau masyarakat awam. Ketergantungan pada persepsi subjektif manusia memiliki sejumlah kelemahan krusial, seperti tingginya risiko kekeliruan identifikasi (*human error*), penurunan tingkat konsistensi saat menangani volume sampel data botani yang besar, serta keterbatasan waktu dan tenaga ahli di lapangan. Ketiadaan sistem klasifikasi terotomatisasi berbasis kecerdasan buatan menjadi faktor penghambat utama dalam efisiensi pengelolaan dan inventarisasi keanekaragaman hayati botani [5].

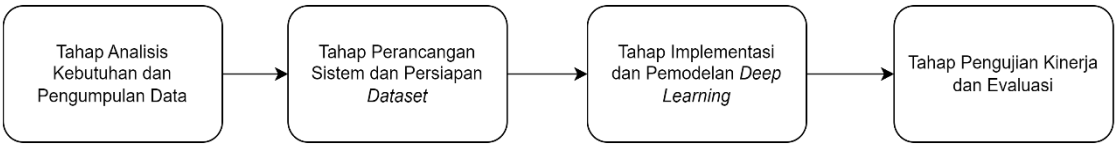
Sebagai solusi teknologi mutakhir, penerapan *Deep Learning* berbasis *Convolutional Neural Network* (CNN) menjadi pendekatan yang sangat handal karena kemampuannya dalam mempelajari hierarki fitur visual citra secara otomatis dan end-to-end, mulai dari fitur ekstraksi level rendah seperti tepi, *gradien*, dan tekstur (*edges/textures*), hingga fitur abstrak tingkat tinggi berupa bentuk semantik objek mahkota bunga [6], [7], [8]. Secara historis, sistem pengenalan citra flora kerap bergantung pada ekstraksi fitur manual (*handcrafted features*) seperti *Scale-Invariant Feature Transform* (SIFT) atau *Histogram of Oriented Gradients* (HOG) yang dikombinasikan dengan pengklasifikasi konvensional seperti *Support Vector Machine* (SVM) [9]. Kendati efektif pada dataset sederhana, pendekatan manual tersebut memiliki kelemahan fatal yakni ketidakmampuan dalam menangkap variasi semantik tingkat tinggi pada objek alami yang kompleks, serta sangat rentan terhadap perubahan kondisi pencahayaan dan latar belakang di lingkungan luar ruangan [10]. Sebaliknya, pemanfaatan *Deep Learning* berbasis CNN mampu melakukan pembelajaran fitur secara otomatis (*feature learning*) dari level piksel dasar hingga representasi bentuk objek yang utuh, sehingga memberikan performa generalisasi yang jauh superior pada kasus klasifikasi citra bunga berbutir halus (*fine-grained*) [11].

Sejumlah penelitian terdahulu telah mengeksplorasi penggunaan arsitektur CNN konvensional atau model berat seperti ResNet-50 [12] dan VGG16 [13] untuk klasifikasi citra flora. Kendati demikian, arsitektur-arsitektur berat tersebut memerlukan kapasitas memori komputasi (VRAM) yang sangat besar, jumlah parameter jutaan, serta waktu pelatihan (*training time*) yang relatif lama, sehingga kurang fleksibel dan tidak efisien apabila diterapkan pada sistem berskala menengah, aplikasi seluler, maupun perangkat tertanam (*edge computing*) berdaya rendah [14]. Sebagai jawaban atas tantangan efisiensi komputasi tersebut, arsitektur MobileNetV2 hadir sebagai solusi optimal. MobileNetV2 dirancang khusus untuk perangkat seluler dan sistem tertanam melalui inovasi struktural berupa *depthwise separable convolution* untuk memangkas jumlah operasi perkalian matriks, *inverted residual blocks* untuk menjaga aliran gradien tetap stabil di seluruh lapisan jaringan, serta linear bottlenecks guna mencegah hilangnya informasi penting pada lapisan aktivasi non-linier berdimensi rendah, sehingga mampu mempertahankan tingkat akurasi tinggi dengan beban komputasi yang minimal [15], [16]. Guna menjamin seluruh siklus perancangan, eksperimen, dan pengujian model berjalan secara sistematis, terstruktur, serta adaptif terhadap evaluasi bertahap, penelitian ini menerapkan metodologi pengembangan perangkat lunak berbasis *Software Development Life Cycle* (SDLC) model iteratif [10], [15].

Penelitian ini bertujuan secara komprehensif untuk merancang, mengimplementasikan, dan menganalisis kinerja arsitektur MobileNetV2 dengan pendekatan model iteratif guna mengotomatisasi klasifikasi 15 kelas spesies bunga tropis berdasarkan dataset masif sebanyak 7.500 citra digital. Selain itu, penelitian ini mengevaluasi performa generalisasi model secara kuantitatif melalui metrik standar evaluasi multi-kelas meliputi akurasi (*Accuracy*), presisi (*Precision*), sensitivitas (*Recall*), dan F1-Score, serta memberikan analisis mendalam terhadap faktor-faktor penyebab kesalahan klasifikasi antarkelas (*misclassification analysis*) untuk pengembangan sistem taksonomi digital di masa depan.

2. METODE PENELITIAN

Penelitian ini dirancang dan dieksekusi melalui kerangka kerja ilmiah yang sistematis, mencakup tahapan metodologis berbasis *Software Development Life Cycle* (SDLC) model iteratif. Pendekatan iteratif ini dipilih karena memungkinkan peneliti untuk melakukan perbaikan, penyetelan hiperparameter (*hyperparameter tuning*), dan evaluasi berulang pada setiap siklus pengembangan (*cycle iteration*) hingga model mencapai ambang batas performa optimal yang ditargetkan [9]. Secara garis besar, alur tahapan penelitian meliputi empat fase utama: (1) Tahap Analisis Kebutuhan dan Pengumpulan Data, (2) Tahap Perancangan Sistem dan Persiapan *Dataset*, (3) Tahap Implementasi dan Pemodelan *Deep Learning*, serta (4) Tahap Pengujian Kinerja dan Evaluasi.



Gambar 1 Tahapan Penelitian

Pada fase analisis kebutuhan, identifikasi masalah difokuskan pada kendala klasifikasi manual bunga tropis yang rentan terhadap subjektivitas dan variasi morfologi kompleks (*high inter-class similarity*). Kebutuhan perangkat keras dan perangkat lunak ditentukan secara cermat, mencakup penggunaan lingkungan komputasi berbasis GPU (*Graphics Processing Unit*), framework *PyTorch* versi terbaru, pustaka pengolahan citra Torchvision, serta manajemen pustaka pendukung berbasis Python. Pengumpulan dataset citra digital dilakukan dengan menghimpun total 7.500 sampel citra berkualitas tinggi yang merepresentasikan 15 kelas spesies bunga tropis populer, di mana setiap kelas memiliki tepat 500 sampel citra untuk menjamin keseimbangan distribusi data (*class balance*) [11]. Rincian lengkap nama ilmiah spesies dan alokasi pembagian data disajikan secara terstruktur pada Tabel 1.

Tabel 1. Pembagian *Dataset* dan Total *Dataset*

No	Nama Kelas *Spesies* Bunga Tropis	Data Latih (70%)	Data Validasi (15%)	Data Uji (15%)	Total gambar
1	*Adenium obesum*	350	75	75	500
2	*Allamanda cathartica*	350	75	75	500
3	*Anthurium andraeanum*	350	75	75	500
4	*Bougainvillea*	350	75	75	500
5	*Catharanthus roseus*	350	75	75	500
6	*Clitoria ternatea*	350	75	75	500
7	*Euphorbia milii*	350	75	75	500
8	*Gardenia jasminoides*	350	75	75	500
9	*Genus Plumeria*	350	75	75	500
10	*Hibiscus rosa sinensis*	350	75	75	500
11	*Ixora*	350	75	75	500
12	*Jasminum sambac*	350	75	75	500
13	*Petunia*	350	75	75	500
14	*Phalaenopsis amabilis*	350	75	75	500
15	*Zinnia elegans*	350	75	75	500
Total	15 Kelas *spesies*	5.250	1.125	1.125	7.500

Fase perancangan (*design & preparation*) mencakup penyiapan alur *pra-pemrosesan* citra digital (*image preprocessing*), penentuan strategi pembagian data (*data splitting*), serta penerapan teknik augmentasi data *(data augmentation*) [11]. Seluruh citra masukan diubah ukurannya (*resizing*) secara seragam menjadi dimensi 224 x 224 x 3 piksel agar sesuai dengan standar lapisan masukan arsitektur MobileNetV2. Nilai *piksel* kemudian dinormalisasi menggunakan parameter rata-rata kanal μ = [0,485; 0,456; 0,406] dan standar deviasi σ = [0,229; 0,224; 0,225] yang diturunkan dari dataset berskala besar *ImageNet*. Untuk menghindari masalah overfitting dan memperkaya variasi fitur spasial selama pelatihan, data pada himpunan pelatihan (training set) dikenakan augmentasi acak meliputi Random Horizontal Flip dengan probabilitas 0,5, Random Rotation pada rentang $\pm$20°, serta Color Jitter untuk variasi pencahayaan, kontras, dan saturasi sebesar 10%. Pembagian keseluruhan dataset dieksekusi secara ketat menggunakan metode *stratified random sampling* dengan proporsi rasio 70% untuk data latih (5.250 citra), 15% untuk data validasi (1.125 citra), dan 15% untuk data uji independen (1.125 citra, di mana masing-masing kelas terdiri atas 75 citra).

Tahap pra-pemrosesan citra memegang peranan krusial dalam memastikan konsistensi dimensi masukan serta meminimalkan bias pencahayaan yang kerap muncul pada citra botani hasil tangkapan lapangan. Normalisasi nilai piksel menggunakan rata-rata dan standar deviasi dari dataset ImageNet dilakukan untuk menyelaraskan distribusi skala warna RGB ke dalam rentang standar yang optimal bagi jaringan saraf tiruan. Selain itu, penerapan augmentasi data seperti rotasi acak dan pembalikan horizontal (horizontal flip) bertujuan untuk mensimulasikan kondisi lingkungan penangkapan citra yang bervariasi, sehingga model terlatih mengenali objek bunga dari berbagai sudut pandang (viewpoint invariance). Pada tahap pemodelan, pemilihan fungsi kerugian Cross-Entropy Loss didasarkan pada karakteristik masalah klasifikasi multikelas, di mana fungsi ini mengukur perbedaan antara distribusi probabilitas prediksi Softmax dan label kebenaran dasar (ground truth) guna memberikan penalti yang proporsional terhadap kesalahan prediksi model pada setiap iterasi epoch.

Fase implementasi dan pemodelan (implementation & modeling) merealisasikan pembangunan arsitektur *Deep Learning* berbasis MobileNetV2 dengan memanfaatkan teknik transfer learning pada *framework PyTorch* [13]. Model ini mengandalkan efisiensi komputasi tingkat tinggi berkat struktur *depthwise separable convolution* yang memisahkan operasi penyaringan spasial dan penggabungan kanal, serta inverted residual blocks yang menghubungkan lapisan berdimensi rendah melalui linear bottlenecks [9]. Seluruh parameter konfigurasi pelatihan pemodelan dirinci secara transparan pada Tabel 2. Lapisan klasifikasi akhir (*classifier head*) dimodifikasi dengan menyesuaikan jumlah neuron output menjadi 15 kelas sesuai jumlah target spesies bunga tropis, serta dihubungkan dengan fungsi aktivasi Softmax untuk menghasilkan estimasi probabilitas kemunculan setiap kelas.

Tabel 2. Konfigurasi Parameter Pelatihan Pemodelan MobileNetV2

Parameter pelatihan	Nilai dan Konfigurasi
Resolusi Dimensi Masukan Citra	224 x 224x 3 *piksel* (RGB)
Batas Maksimum Siklus Pelatihan	30 *epoch*
Ambang Batas Kesabaran (*Patience*)	5 *epoch (Early Stopping)*
Ukuran Kelompok Sampel (*Batch Size*)	32 sampel per iterasi
Laju Pembelajaran Awal (*Initial Learning Rate*)	0,00005
Algoritma Pengoptimasi (*Optimizer*)	*Adam (optimizer.zero_grad(), optimizer.step())*
Mekanisme Penjadwal Laju Pembelajaran	*scheduler.step(epoch_val_loss) (ReduceLROnPlateau)*
Fungsi Kerugian (*Loss Function*)	*Cross-Entropy Loss (nn.CrossEntropyLoss())*
Fungsi Aktivasi Lapisan Output	*Softmax*
Total Kelas	15 Kelas *spesies* bunga tropis

Algoritma pelatihan dieksekusi secara iteratif dengan memantau metrik performa pada setiap siklus epoch. Proses validasi dijalankan secara periodik di setiap akhir epoch tanpa melibatkan kalkulasi gradien balik (*with torch.no_grad():*) untuk mengukur tingkat kesalahan pada data validasi. Bobot parameter model dengan performa terbaik (*best model weights*) disimpan secara otomatis ke media penyimpanan eksternal (*torch.save(model.state_dict(), MODEL_SAVE_PATH)*) manakala tercatat penurunan nilai kerugian validasi (*validation loss*) dibandingkan iterasi sebelumnya. Selain itu, fungsi *Early Stopping* diaktifkan dengan nilai *patience* setara 5 *epoch* untuk menghentikan proses pelatihan secara dini apabila kurva validation loss mengalami stagnasi atau kenaikan berkelanjutan, sehingga efektif mencegah gejala *overfitting* [16].

Fase pengujian dan evaluasi (*testing & evaluation*) menguji tingkat generalisasi model optimal pada himpunan data uji independen sebanyak 1.125 citra yang belum pernah dilihat oleh model selama proses pelatihan. Kinerja model diukur secara kuantitatif melalui konstruksi *Confusion Matrix* multikelas serta perhitungan metrik evaluasi standar meliputi akurasi (*Accuracy*), presisi (*Precision*), perolehan (*Recall*), dan skor harmonik (*F1-Score*) yang dihitung menggunakan pendekatan makro dan berbobot (*Weighted Average*) berdasarkan formulasi matematis *One-vs-Rest* (OvR) [14], [15], sebagaimana ditunjukkan pada persamaan (1) hingga (4):

$$Accuracy = \frac{\sum TP}{Total\ data} \quad (1)$$

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

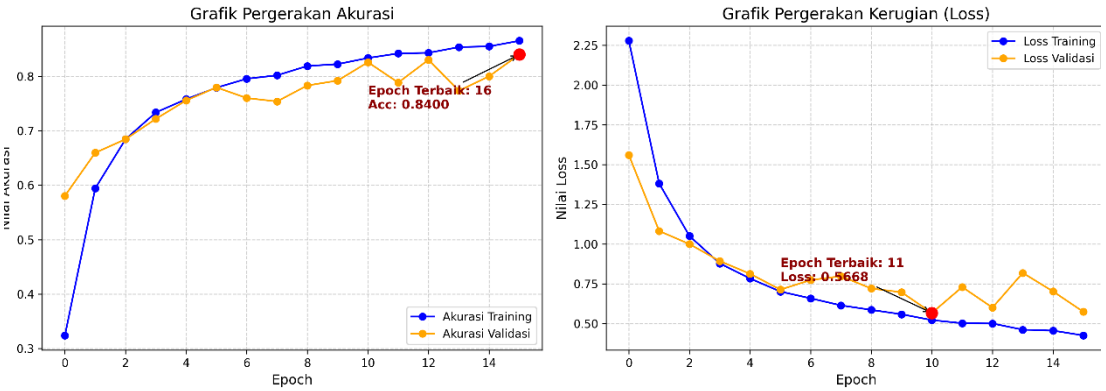
$$Recall = \frac{TP}{TP+FN} \quad (3)$$

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

$\sum TP$ merepresentasikan total seluruh sampel citra dari 15 kelas bunga tropis yang berhasil diprediksi secara benar (True Positive), sedangkan Total data} menyatakan keseluruhan jumlah sampel pada data uji independen (yaitu 1.125 citra). Untuk pengujian tiap kelas, TP menunjukkan sampel kelas target yang terprediksi tepat, FP (*False Positive*) menunjukkan sampel dari kelas lain yang keliru diprediksi sebagai kelas target, serta FN (*False Negative*) menunjukkan sampel dari kelas target yang keliru diprediksi sebagai kelas lain. Metrik $F1 - Score$ menghitung rata-rata harmonik antara *precision* dan *recall* untuk memberikan gambaran keseimbangan performa model pada dataset multikelas.

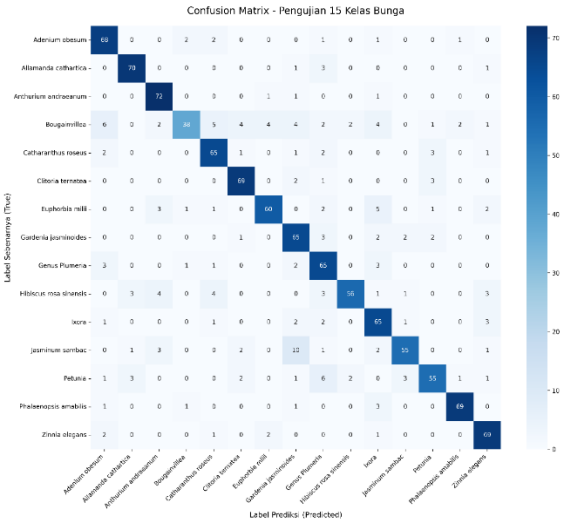
3. HASIL DAN ANALISIS

Proses eksekusi pelatihan model MobileNetV2 menggunakan akselerasi perangkat keras GPU pada *framework PyTorch* berjalan secara stabil sesuai rancangan iteratif SDLC. Pergerakan kurva metrik akurasi (*Accuracy*) dan fungsi kerugian (*Loss*) selama proses pelatihan dan validasi direkam serta divisualisasikan untuk menganalisis konvergensi model. Berdasarkan visualisasi kedua grafik tersebut, proses pembelajaran arsitektur MobileNetV2 diuraikan ke dalam tiga fase utama. Pada fase awal (*epoch* 1 hingga 4), model mengawali pembelajaran dengan adaptasi ekstraksi fitur di mana Validation *Accuracy* berada di kisaran 58% dengan *Validation Loss* di atas 1,5, namun kurva langsung menanjak dan menurun tajam secara eksponensial. Memasuki fase konvergensi (epoch 5 hingga 10), model mulai menemukan pola fitur yang kompleks dan stabil dengan *Validation Accuracy* konsisten di rentang 75% hingga 80%, serta jarak (gap) kurva training dan validation loss yang menyempit. Selanjutnya pada fase penentuan (*epoch* 11 hingga 16), model mencapai titik optimal generalisasinya di mana pada *epoch* ke-11 *Validation Loss* menyusut ke titik minimum 0,5668 dan pada epoch ke-16 akurasi validasi menyentuh angka maksimal 84,00% (0,8400). Integrasi *Learning Rate Scheduler* dan mekanisme *Early Stopping* yang memutus pelatihan pada epoch ke-16 terbukti efektif menjaga stabilitas bobot optimal serta menghindarkan model dari gejala *overfitting*.



Gambar 2. Grafik Pergerakan Akurasi dan Kerugian Pelatihan MobileNetV2

Evaluasi kinerja generalisasi secara objektif kemudian dieksekusi terhadap 1.125 citra data uji independen dengan memuat berkas bobot optimal (mobilenetv2_bunga_best.pth). Hasil pemetaan prediksi multi-kelas divisualisasikan dalam bentuk Confusion Matrix guna menelaah distribusi ketepatan prediksi pada masing-masing *spesies* bunga tropis.



Gambar 3. Confusion Matrix Klasifikasi 15 Kelas Bunga Tropis

Berdasarkan *confusion matrix* tersebut, mayoritas sampel berhasil diprediksi dengan tingkat akurasi tinggi pada diagonal utama matriks. Sebagai contoh, spesies *Anthurium andraeanum* mencatatkan 72 prediksi benar dari total 75 sampel uji, *Allamanda cathartica* mencatatkan 70 prediksi benar, serta spesies *Clitoria ternatea*, *Phalaenopsis amabilis*, dan *Zinnia elegans* masing-masing berhasil dikenali dengan tepat sebanyak 69 sampel dari 75 sampel uji.

Meskipun demikian, analisis mendalam terhadap sel-sel di luar diagonal utama mengungkapkan adanya pola misklasifikasi pada beberapa kelas tertentu yang memiliki kemiripan morfologi visual yang tinggi. Kasus kesalahan klasifikasi paling signifikan terjadi pada kelas *Bougainvillea*, di mana hanya 38 sampel yang berhasil diprediksi benar, sementara 5 sampel lainnya keliru dikenali sebagai *Catharanthus roseus*, 4 sampel sebagai Clitoria ternatea, dan 4 sampel lainnya terdeteksi sebagai *Euphorbia milii*. Tingginya tingkat kesalahan pada kelas *Bougainvillea* ini secara botani disebabkan oleh keragaman luar biasa pada warna seludang bunga (*bract*) yang mencakup spektrum merah, ungu, merah muda, hingga jingga terang, serta kesamaan struktur susunan klaster bunga majemuk dengan tanaman pembanding. Selain itu, kelompok bunga dengan dominasi kelopak putih seperti Genus Plumeria (*Precision* 0,71) dan Gardenia jasminoides (*Precision* 0,72) kerap mengalami tumpang tindih fitur visual (*spectral overlapping*) dengan *spesies Jasminum sambac*, yang diatasi model melalui ekstraksi fitur tekstur permukaan kelopak.

Untuk memberikan gambaran kuantitatif yang transparan dan menyeluruh, rincian performa evaluasi per kelas yang mencakup nilai *Precision*, *Recall*, *F1-Score*, dan jumlah dukungan sampel (*Support*) disajikan secara lengkap pada Tabel 3.

Tabel 3. Hasil penelitian

Kelas *Spesies* Bunga Tropis	***Precision***	***Recall***	***F1-score***	***Support* (Sampel Uji)**
Adenium obesum	0,81	0,91	0,86	75
Allamanda cathartica	0,91	0,93	0,92	75
Anthurium andraeanum	0,86	0,96	0,91	75
Bougainvillea	0,88	0,51	0,64	75
Catharanthus roseus	0,81	0,87	0,84	75
Clitoria ternatea	0,87	0,92	0,90	75
Euphorbia milii	0,90	0,80	0,85	75
Gardenia jasminoides	0,72	0,87	0,79	75
Genus Plumeria	0,71	0,87	0,78	75
Hibiscus rosa sinensis	0,93	0,75	0,83	75
Ixora	0,74	0,87	0,80	75
Jasminum sambac	0,89	0,73	0,80	75
Petunia	0,85	0,73	0,79	75
Phalaenopsis amabilis	0,95	0,92	0,93	75
Zinnia elegans	0,84	0,92	0,88	75
Overall Accuracy			0,84 (84%)	1.125
Macro Average	0,84 (84%)	0,84 (84%)	0,83 (83%)	1.125
Weighted Average	0,84 (84%)	0,84 (84%)	0,83 (83%)	1.125

Berdasarkan rangkuman hasil pada Tabel 3, capaian akurasi keseluruhan (*Overall Accuracy*) sebesar 84,0% serta *Weighted F1-Score* sebesar 83,0% secara empiris membuktikan bahwa arsitektur MobileNetV2 sangat efektif dan handal dalam mengenali karakteristik pola visual dari 15 kelas spesies bunga tropis yang diuji [8]. Performa tertinggi diraih oleh *spesies Phalaenopsis amabilis* dengan perolehan *F1-Score* mencapai 0,93 (*Precision* 0,95 dan *Recall* 0,92). Tingginya skor pada spesies anggrek bulan ini mengindikasikan bahwa bentuk morfologi labellum yang khas dan struktur kelopak simetris bilateral berhasil diekstraksi secara sangat optimal oleh lapisan konvolusi jaringan. Di sisi lain, variasi performa terendah tercatat pada kelas *Bougainvillea* dengan *F1-Score* 0,64 akibat kompleksitas variasi warna seludang bunga.

Temuan evaluasi ini memberikan umpan balik yang sangat berharga sesuai prinsip pendekatan iteratif SDLC, di mana siklus pengembangan berikutnya direkomendasikan untuk menambahkan teknik augmentasi warna khusus (*color balance augmentation*), memperkaya jumlah sampel pada kelas minoritas, serta mengintegrasikan modul mekanisme perhatian spasial (*attention mechanism*) guna meningkatkan sensitivitas model terhadap detail mikro pada bagian mahkota bunga.

4. KESIMPULAN

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, dapat disimpulkan bahwa tujuan penelitian yang dirumuskan pada bab Pendahuluan yakni mengembangkan sistem otomatisasi klasifikasi jenis bunga tropis untuk menciptakan alur kerja yang efisien bagi Garden ABC telah berhasil dicapai dan selaras secara menyeluruh dengan bab Hasil dan Pembahasan. Penerapan arsitektur deep learning MobileNetV2 dengan strategi *transfer learning* terbukti efektif dalam mengenali 15 spesies bunga tropis dari dataset citra digital, dengan mencapai akurasi pengujian sebesar 84% serta skor *F1-Score* rata-rata sebesar 83% pada data uji independen. Meskipun model menunjukkan performa yang sangat tinggi pada mayoritas kelas bunga, analisis *Confusion Matrix* mengungkap adanya tantangan kesalahan klasifikasi pada spesies dengan variasi warna seludang (*bract*) yang kompleks seperti Bougainvillea dan tumpang tindih fitur visual pada kelompok bunga kelopak putih. Temuan ini menegaskan bahwa penggunaan *feature extraction* berbasis tekstur dan augmentasi citra acak mampu meminimalkan dampak keterbatasan fitur visual tersebut.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Bapak Hadi Zakaria, S.Kom., M.Kom., M.M. selaku dosen pembimbing atas bimbingan, arahan, dan dukungan yang diberikan selama penyelesaian penelitian ini. Ucapan terima kasih juga ditujukan kepada seluruh keluarga serta rekan-rekan yang senantiasa memberikan doa, semangat, dan dukungan hingga penelitian ini dapat terselesaikan dengan baik.

REFERENSI

[1] V. Ayumi, “Pengenalan Objek Bunga Berbasis Deep Learning Menggunakan Model Resnet50 dan MobileNet-v2,” *JSAI J. Sci. Appl. Informatics*, vol. 5, no. 3, pp. 188–193, 2022, doi: 10.36085/jsai.v5i3.3613.

[2] R. J. Hendri Butar-Butar and N. L. Marpaung, "Deep Learning untuk Identifikasi Daun Tanaman Obat Menggunakan Transfer Learning MobileNetV2," *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 142–148, May 2023, doi: 10.30591/jpit.v8i2.5217.

[3] O. V. Putra, M. Z. Mustaqim, and D. Muriatmoko, "Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2," *Techno.COM*, vol. 22, no. 3, pp. 562–575, 2023, doi: 10.33633/tc.v22i3.8516.

[4] D. A. Pangestu, O. Q. Aziz, and C. Crysdian, "Klasifikasi Penyakit pada Tanaman Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 10, no. 2, pp. 235–248, May 2025, doi: 10.14421/jiska.2025.10.2.235-248.

[5] E. R. Anjasmara, F. Fattah, and A. W. M. Gaffar, "Implementasi Model MobileNetV2 pada ESP-32 CAM untuk Klasifikasi Botol Plastik," *J. Minfo Polgan*, vol. 15, no. 2, pp. 1262–1271, 2026, doi: 10.33395/jmp.v15i2.16197.

[6] B. A. Wijaya, P. J. Gea, A. D. Gea, A. Sembiring, and C. M. S. Hutagalung, "Satellite Images Classification using MobileNet V-2 Algorithm," *Sink. J. dan Penelit. Tek. Inform.*, vol. 7, no. 4, pp. 2316–2326, 2023, doi: 10.33395/sinkron.v8i4.12949.

[7] R. I. Y. Vianda, P. Anjarwati, H. A. Pratama, R. M. Akbar, and R. D. Irawan, "Klasifikasi Citra Bunga Multikelas Menggunakan Convolutional Neural Network (CNN)," in *Prosiding Seminar Nasional Teknologi Informasi dan Bisnis (SENATIB)*, 2025, pp. 367–376. doi: 10.47701/0d10j421.

[8] A. Anggraini and H. Zakaria, "Penerapan Metode Deep Learning Pada Aplikasi Pembelajaran Menggunakan Sistem Isyarat Bahasa Indonesia Menggunakan Convolutional Neural Network (Studi Kasus: SLB-BC Mahardika Depok)," *JURIHUM J. Inov. dan Hum.*, vol. 1, no. 4, pp. 452–464, 2023, [Online]. Available: https://jurnalmahasiswa.com/index.php/Jurihum/article/view/723

[9] I. I. Khoirunnisa, A. Fadlil, and H. Yuliansyah, "Perbandingan Kinerja MobileNetV2 dan VGG16 dalam Klasifikasi Penyakit pada Citra Daun Tanaman Cabai," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 11, no. 1, pp. 70–82, 2026, doi: 10.14421/jiska.5075.

[10] M. F. Nazuli, M. Fachrurrozi, M. Q. Rizqie, Abdiansah, and M. Ikhsan, "A Image Classification of Poisonous Plants Using the MobileNetV2 Convolutional Neural Network Model Method," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 24, no. 2, pp. 371–380, 2025, doi: 10.30812/matrik.v24i2.4284.

[11] I. Setiani, A. Suwondo, and N. Hasanah, "Smart Tea Farming Untuk Klasifikasi Penyakit Daun Teh Berbasis MobileNetV3-Small pada Perangkat Edge," *J. Innov. Creat.*, vol. 6, no. 2, 2026, doi: 10.31004/joecy.v6i2.10839.

[12] Y. Gulzar, "Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique," *Sustainability*, vol. 15, no. 3, p. 1906, 2023, doi: 10.3390/su15031906.

[13] A. A. Utomo and S. Mulyono, "Perbandingan MobileNetV2 dan DenseNet121 pada Klasifikasi Terumbu Karang Menggunakan Convolutional Neural Network," *J. Rekayasa Sist. Inf. dan Teknol.*, vol. 2, no. 3, pp. 930–941, 2025, doi: 10.70248/jrsit.v2i3.1844.

[14] D. S. Alfan and I. Kumalasari, "Implementasi Model Deep Learning MobileNetV2 untuk Klasifikasi Citra Melanoma Berbasis Web," *J. Inf. Syst. Res.*, vol. 7, no. 3, pp. 670–680, 2026, doi: 10.47065/josh.v7i6.8848.

[15] T. Gunawan, R. K. Niswatin, and D. P. Pamungkas, "Implementasi Klasifikasi Dua Tahap Berbasis MobileNetV2 pada Aplikasi Android untuk Deteksi dan Klasifikasi Varietas Mangga," in *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, 2026, pp. 2902–2909. doi: 10.29407/6dkt6g67.

[16] D. Ramayanti, S. D. Asri, and Lionie, "Implementasi Model Arsitektur VGG16 dan MobileNetV2 Untuk Klasifikasi Citra Kupu-Kupu," *JSAI J. Sci. Appl. Informatics*, vol. 5, no. 3, pp. 182–187, 2022, doi: 10.36085/jsai.v5i3.2864.