



Klasifikasi Jenis Bunga Menggunakan Algoritma *Convolutional Neural Network (CNN)*

Dwi Okta Djoas¹, Ade Irgi Firdaus², Hilda Apriliya Ningsih³, Indry Anggraeny⁴, Riefaldi Diofano Saputra⁵

¹⁻⁵Program Studi Informatika, Universitas Bina Sarana Informatika Jakarta, Indonesia

Email author: 15230125@bsi.ac.id¹, 15230285@bsi.ac.id², 15230253@bsi.ac.id³, 15230282@bsi.ac.id⁴, 15230116@bsi.ac.id⁵

Article Info

Article history:

Received September 3, 2025

Revised Desember 3, 2025

Accepted Januari 4, 2026

Keywords:

Image Classification

CNN

EfficientNet

Flowers

Deep Learning

ABSTRACT

This research aims to develop a multiclass flower image classification system using the Convolutional Neural Network (CNN) algorithm with the EfficientNet architecture. The main problem addressed is the difficulty of manual identification of flower species that share high visual similarity. The research stages include collecting 17,299 flower images across 19 classes, performing data preprocessing such as image resizing, pixel normalization, and augmentation, followed by model training using the EfficientNet transfer learning approach. The model was trained for 10 epochs with an 80:20 training-validation data split. The evaluation results show that the model achieved a validation accuracy of 98.05% with a loss value of 0.0968, and an average precision, recall, and F1-score of 0.98. The trained model was then implemented into a web-based application built using the Next.js framework, enabling users to upload flower images and obtain real-time classification results via the Hugging Face API. The system successfully identified flower species with a confidence level of 99.87%. These findings demonstrate that combining a modern CNN architecture with transfer learning provides efficient and highly accurate flower classification performance, which can be effectively implemented for educational and digital conservation purposes.

Corresponding Author:

Ade Irgi Firdaus,

Universitas Bina Sarana Informatika

Jl. Kramat Raya No.98, RT.2/RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat, Daerah Khusus Ibukota Jakarta 10450

Email: 15230285@bsi.ac.id



1. INTRODUCTION

Pada kemajuan teknologi kecerdasan buatan, khususnya dalam area pengolahan gambar digital, Salah satu contohnya adalah kemampuan untuk mengenali dan mengelompokkan objek visual, seperti berbagai jenis bunga. Berbagai studi *deep learning* dalam *botanical image recognition*, khususnya pada spesies tanaman obat, melaporkan akurasi yang sangat tinggi pada dataset terbatas, namun pada praktik nyata dan dataset besar, akurasi identifikasi spesies biasanya berada di kisaran 85%-95%, dengan

beberapa studi spesifik yang mencapai di atas 95% (Ki & Sharma, 2024). Bunga sebagai objek penelitian memiliki tingkat kemiripan visual yang tinggi antarspesies, sehingga proses identifikasi manual sering kali tidak akurat dan membutuhkan keahlian khusus. Di sisi lain, kemudahan akses terhadap perangkat komputasi dan melimpahnya data citra bunga dari sumber publik seperti Kaggle mendorong perlunya penelitian tentang sistem klasifikasi citra otomatis berbasis *deep learning*. Pendekatan ini memungkinkan proses identifikasi bunga dilakukan secara efisien, cepat, dan presisi tinggi untuk mendukung kebutuhan konservasi, edukasi, serta penelitian botani.

Berbagai penelitian telah membuktikan efektivitas *Convolutional Neural Network* (CNN) dalam klasifikasi citra bunga multikelas. Studi komparatif terkini menunjukkan bahwa berbagai arsitektur CNN modern telah mencapai performa yang mengesankan dalam *plant recognition*. *Vision Transformers* dan *EfficientNetV2* menunjukkan keunggulan dibandingkan CNN generasi sebelumnya, dengan ViT mencapai akurasi superior dalam deteksi penyakit tanaman (Barman et al., 2024), sementara kombinasi *EfficientNetV2* dengan *Swin Transformer* memberikan performa klasifikasi yang lebih baik dibandingkan CNN konvensional (Sun et al., 2024). Temuan ini diperkuat oleh sebuah tinjauan sistematis yang menegaskan bahwa pendekatan berbasis *deep learning* secara konsisten mencapai akurasi klasifikasi yang jauh lebih unggul rata-rata 98.8% dibandingkan dengan metode *machine learning* lainnya, yang secara efektif menetapkan standar presisi baru untuk analisis tanaman (Chug et al., 2023). Penelitian oleh (Predianto & Sutomo, 2024) berhasil mencapai akurasi 85% dalam klasifikasi tiga jenis anggrek menggunakan metode *R-CNN*. Sementara itu, (Rumui et al., 2025) membandingkan CNN konvensional dengan model *fine-tuning VGG16* pada lima kelas bunga dan menemukan keunggulan signifikan pada pendekatan *transfer learning*, di mana *VGG16* menghasilkan akurasi 90% sedangkan CNN hanya mencapai 48%. Selanjutnya, (Pratiwi et al., 2021) melalui aplikasi Android "*Flower Scanner*", melaporkan validasi klasifikasi lima jenis bunga berbasis CNN dengan akurasi lebih dari 99%. Penelitian (Sibarani et al., 2023) juga membuktikan kemampuan CNN dalam klasifikasi tanaman hias dengan nilai F1-score dan presisi mencapai 1,00 pada beberapa kelas populer. Selain itu, sejumlah studi menyoroti pentingnya teknik *augmentation*, *fine-tuning*, dan pemanfaatan dataset kompleks seperti *Oxford17* dan *Oxford102*, yang mampu meningkatkan performa model hingga masing-masing 84% dan 64%

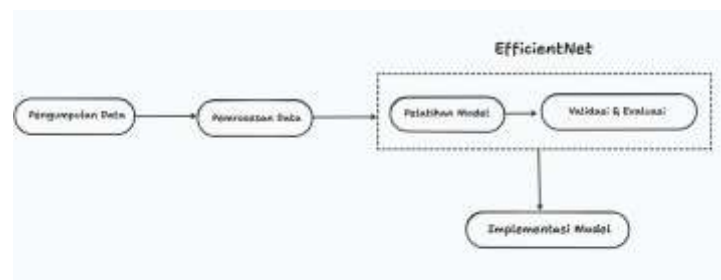
Dari berbagai kajian tersebut, tren penelitian terkini menegaskan keunggulan *transfer learning* dalam memperkuat kemampuan generalisasi model, khususnya pada dataset bunga berskala besar dan variatif. Namun, sebagian besar penelitian masih terbatas pada jumlah kelas yang sedikit, penggunaan dataset kecil, atau model CNN konvensional tanpa optimalisasi arsitektur *modern*. Studi menunjukkan bahwa tantangan utama dalam *flower classification* mencakup kesulitan dalam mengidentifikasi area diskriminatif pada citra bunga dan tingginya kemiripan visual antar spesies yang berbeda. (Zhang et al., 2025) memperkuat temuan ini dengan menunjukkan adanya kemiripan antar-kelas yang besar serta variasi intra-kelas yang signifikan dalam aspek bentuk, distribusi warna, dan kondisi pencahayaan. Lebih lanjut, kesulitan klasifikasi muncul dari variasi antar-kelas yang secara visual kecil dibandingkan variasi intra-kelas yang besar (Borhani et al., 2022). Penelitian ini hadir untuk menjawab keterbatasan tersebut dengan mengembangkan sistem klasifikasi bunga multikelas yang terdiri dari 19 kelas bunga khas Indonesia menggunakan dataset berskala besar dan arsitektur CNN modern, yaitu *EfficientNet*. *EfficientNet* dipilih karena menunjukkan keunggulan dalam efisiensi komputasi dan akurasi pada tugas-tugas *botanical classification* seperti klasifikasi penyakit daun tanaman, menjadikannya arsitektur yang sesuai untuk klasifikasi bunga multikelas (Atila et al., 2020). Fokus penelitian diarahkan pada optimalisasi CNN mutakhir dalam lingkungan biodiversitas tinggi dan kondisi pencahayaan variatif, yang umum ditemukan di Indonesia.

Tujuan utama penelitian ini adalah merancang, mengembangkan, dan mengimplementasikan sistem klasifikasi bunga otomatis berbasis CNN yang adaptif, efisien, dan akurat. Diharapkan hasil penelitian ini dapat memberikan kontribusi bagi bidang botani, konservasi, serta pertanian nasional, khususnya dalam mendukung digitalisasi identifikasi spesies bunga secara cepat dan presisi.

2. METHOD

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan algoritma *Convolutional Neural Network* (CNN) sebagai teknik utama dalam klasifikasi citra digital bunga. Pendekatan ini dipilih karena CNN mampu mengekstraksi fitur spasial dan hierarkis secara otomatis tanpa memerlukan rekayasa fitur manual, sehingga efisien dan akurat dalam mengenali pola visual yang kompleks seperti bentuk kelopak, warna, dan tekstur bunga.

Adapun alur penelitian dapat dilihat pada Gambar 1, yang menggambarkan proses penelitian mulai dari tahap pengumpulan data hingga implementasi model.



Gambar 1. Alur Penelitian

2.1. Data Penelitian

Dataset yang digunakan merupakan dataset publik yang berisi 17.299 citra bunga, dikelompokkan ke dalam 19 kelas berbeda, yaitu *Astilbe*, *Bellflower*, *Black Eyed Susan*, *Calendula*, *California Poppy*, *Carnation*, *Common Daisy*, *Coreopsis*, *Daffodil*, *Dandelion*, *Iris*, *Lavender*, *Lotus*, *Magnolia*, *Orchid*, *Rose*, *Sunflower*, *Tulip*, dan *Water Lily*.

Pembagian dataset dilakukan secara acak namun terkontrol, dengan memastikan proporsi setiap kelas tetap seimbang antara data pelatihan dan validasi. Pendekatan ini bertujuan untuk menghindari bias data serta menjamin keadilan distribusi antar kelas selama proses *learning*.

2.2. Pra-pemrosesan Data

Menurut (Ibrahim et al., 2023), tahapan pra-pemrosesan citra merupakan langkah penting dalam sistem klasifikasi berbasis CNN karena secara langsung memengaruhi kestabilan pelatihan, kualitas fitur yang diekstraksi, serta akurasi hasil klasifikasi. Proses ini berfungsi untuk meningkatkan kualitas data mentah dengan menyesuaikan ukuran, format, dan distribusi intensitas piksel agar citra dapat diolah secara optimal oleh jaringan saraf konvolusional. Selain itu, integrasi metode pra-pemrosesan seperti *resizing*, *grayscale conversion*, dan *thresholding* mampu memperjelas kontur serta mengurangi noise yang dapat mengganggu deteksi fitur visual.

Pada penelitian ini, tahapan pra-pemrosesan dilakukan untuk menyiapkan data agar sesuai dengan format input jaringan saraf konvolusional serta meningkatkan kualitas pelatihan. Proses ini mencakup perubahan ukuran citra menjadi 256×256 piksel, normalisasi nilai piksel dari rentang 0–255 menjadi 0–1, serta augmentasi data seperti rotasi, translasi, dan pembalikan horizontal untuk memperluas variasi data pelatihan. Selain itu, diterapkan optimalisasi *data pipeline* menggunakan *caching* dan *prefetching* agar proses pemuatan citra berlangsung efisien selama pelatihan.

Pendekatan ini terbukti dapat mempercepat konvergensi model dan meningkatkan kemampuan generalisasi terhadap variasi visual objek. Dalam konteks *botanical image processing*, pra-pemrosesan mengikuti *pipeline* pengolahan citra tanaman yang mencakup standarisasi ukuran,

normalisasi intensitas, peningkatan kualitas, dan augmentasi untuk meningkatkan *robustnes* terhadap variasi pencitraan dan latar kompleks (Hong & Zhou, 2025). Penelitian terkini menunjukkan bahwa augmentasi khusus domain yang menjaga morfologi daun dan menonjolkan tekstur penyakit terbukti meningkatkan generalisasi pada klasifikasi daun tanaman, dengan penerapan yang serupa dapat diterapkan untuk flower classification (Min et al., 2023). Sebagaimana dijelaskan dalam penelitian (Insan, n.d.), penerapan pra-pemrosesan citra dan augmentasi mampu memperkaya representasi fitur visual serta meningkatkan *robustnes* model CNN dalam menganalisis pola kompleks pada data citra

2.3. Arsitektur dan Desain Model CNN

Menurut (Dan et al., 2023) *Convolutional Neural Network* (CNN) merupakan arsitektur jaringan saraf tiruan yang dirancang untuk mengenali pola visual melalui proses ekstraksi fitur spasial secara bertingkat menggunakan operasi konvolusi. CNN banyak digunakan dalam klasifikasi citra karena kemampuannya dalam mengidentifikasi tepi, bentuk, dan tekstur dari data visual secara otomatis.

Dalam penelitian ini, arsitektur CNN yang digunakan berbasis pada *EfficientNet*, yaitu model *transfer learning* modern yang menggabungkan efisiensi komputasi dan akurasi tinggi melalui teknik *compound scaling* (Tan & Le, 2021). *EfficientNet* dan *EfficientNetV2* menerapkan *compound scaling*, *training-aware NAS*, *Fused-MBConv*, dan *progressive learning* untuk efisiensi parameter dan kecepatan latih, efektif untuk transfer learning pada klasifikasi citra (Tan & Le, 2021). Struktur umum model ditunjukkan pada Tabel 1, yang menggambarkan setiap lapisan utama beserta konfigurasi dan parameternya.

Tabel 1. Struktur Arsitektur Model Convolutional Neural Network (CNN)

| Lapisan | Deskripsi | Parameter |
|------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------|
| <i>Input Layer</i> | Menerima citra bunga berukuran 256×256 piksel dengan tiga kanal warna yaitu RGB. | - |
| <i>Backbone</i> | Lapisan <i>pretrained model</i> yang berfungsi mengekstraksi fitur visual tingkat tinggi dari citra bunga. | Lapisan awal dibekukan (<i>frozen</i>), 40 lapisan terakhir diaktifkan kembali (<i>fine-tuning</i>). |
| <i>Fully Connected Layer</i> | Menggabungkan hasil ekstraksi fitur dan melakukan pembelajaran hubungan non-linear. Dilengkapi dengan dropout 0,5 untuk mencegah <i>overfitting</i> . | <i>ReLU activation</i> , dropout 0,5 |
| <i>Output Layer</i> | Menghasilkan hasil klasifikasi akhir untuk 19 kelas bunga. | <i>Softmax activation</i> , 19 neuron |

Dengan rancangan arsitektur ini, model CNN mampu melakukan klasifikasi multikelas citra bunga secara otomatis dan efisien, serta memberikan hasil yang akurat pada data pelatihan maupun validasi.

2.4 Proses Pelatihan Model CNN

Proses pelatihan dilakukan untuk mengoptimalkan kemampuan model dalam mengenali pola visual citra bunga. Tahapan ini mencakup penentuan parameter pelatihan, algoritma optimisasi, dan mekanisme evaluasi selama proses pembelajaran berlangsung. Pelatihan model CNN pada dasarnya bertujuan untuk meminimalkan fungsi *loss* dengan cara memperbarui bobot jaringan secara iteratif menggunakan algoritma *gradient descent*, yaitu metode optimisasi yang digunakan untuk menemukan bobot terbaik dalam proses pembelajaran mesin (Nugroho et al., 2023).

Secara matematis, proses pembaruan bobot pada model CNN dinyatakan dengan persamaan:

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} L(\theta_t)$$

Dengan keterangan :

θ_t = bobot model pada iterasi ke- t ,

η = *learning rate* yang menentukan besar langkah pembaruan bobot,

$\nabla_{\theta} L(\theta_t)$ = *gradient* fungsi *loss* terhadap bobot model pada iterasi ke- t .

Persamaan ini menunjukkan bahwa setiap parameter θ diperbarui dengan cara mengurangnya sebesar nilai *gradient* dikalikan dengan *learning rate*. Semakin kecil nilai *gradient*, semakin dekat model menuju titik minimum fungsi *loss*, yang berarti kesalahan prediksi semakin kecil.

2.5. Evaluasi Model

Tahapan evaluasi model merupakan langkah penting untuk menilai performa sistem klasifikasi citra berdasarkan kemampuan generalisasi terhadap data baru. Menurut (Anggara et al., 2025), proses evaluasi bertujuan memastikan bahwa model tidak hanya bekerja dengan baik pada data pelatihan, tetapi juga mampu memberikan hasil yang akurat dan andal terhadap data yang belum pernah dilihat sebelumnya.

Metrik evaluasi yang digunakan dalam penelitian ini meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Keempat metrik ini memberikan gambaran menyeluruh tentang efektivitas model dalam mengenali pola citra dan mengklasifikasikannya ke dalam kelas yang tepat. Kombinasi *accuracy*, *precision*, *recall*, dan *F1-score* sangat efektif untuk evaluasi *plant classification*, khususnya saat menghadapi ketidakseimbangan kelas (Saleem & Potgieter, 2020). Selain itu, *confusion matrix* digunakan untuk memvisualisasikan kesalahan klasifikasi antar kelas, sedangkan *loss function* seperti *Cross-Entropy Loss* menjadi indikator numerik seberapa jauh hasil prediksi model dari label sebenarnya.

1. Accuracy

Akurasi menunjukkan seberapa besar proporsi prediksi yang benar dibandingkan dengan total data uji, dan dapat dihitung menggunakan rumus:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

dengan *TP*(True Positive), *TN*(True Negative), *FP*(False Positive), dan *FN*(False Negative).

2. Precision

Presisi mengukur ketepatan model dalam memberikan prediksi positif yang benar terhadap seluruh prediksi positif:

$$\text{Precision} = \frac{TP}{TP + FP}$$

3. Recall

Recall, atau sensitivitas, mengukur sejauh mana model mampu mendeteksi seluruh data positif yang benar dalam dataset:

$$\text{Recall} = \frac{TP}{TP + FN}$$

4. F1-Score

F1-Score merupakan rata-rata harmonik antara presisi dan *recall* yang digunakan untuk menilai keseimbangan antara keduanya:

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

5. Loss Function

Fungsi *loss* digunakan untuk mengukur seberapa jauh hasil prediksi model dari label sebenarnya. Dalam penelitian ini digunakan fungsi *Cross-Entropy Loss*, yang dirumuskan sebagai:

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N \log P(y_i | x_i; \theta)$$

dengan N adalah jumlah sampel, y_i label sebenarnya, dan $P(y_i | x_i; \theta)$ probabilitas hasil prediksi untuk kelas ke- i . Nilai *loss* yang kecil menunjukkan bahwa model semakin akurat dalam meminimalkan kesalahan klasifikasi.

Nilai-nilai metrik ini diperoleh dengan membandingkan hasil prediksi model terhadap label aktual pada data validasi. Model yang baik memiliki nilai akurasi, presisi, recall, dan *F1-score* yang tinggi, serta nilai *loss* yang rendah.

3. RESULT DAN ANALISIS

3.1. Konfigurasi Pelatihan Model

Tahap pelatihan model bertujuan untuk mengoptimalkan kemampuan jaringan saraf konvolusional dalam mengenali dan mengklasifikasikan berbagai jenis bunga berdasarkan citra digital. Proses pelatihan dilakukan menggunakan pendekatan *transfer learning* dengan model *EfficientNet* sebagai *backbone*, yang telah dilatih sebelumnya pada dataset skala besar (*ImageNet*). Model kemudian disesuaikan (*fine-tuned*) dengan dataset bunga yang digunakan pada penelitian ini untuk memperoleh hasil yang lebih spesifik dan akurat.

Selama proses pelatihan, digunakan algoritma optimisasi Adam, yang dikenal efektif dalam mempercepat konvergensi model dengan pembaruan bobot adaptif pada setiap iterasi. Fungsi *loss* yang digunakan adalah *Sparse Categorical Crossentropy*, karena sesuai untuk masalah klasifikasi multikelas dengan label numerik. Parameter pelatihan diatur agar model dapat belajar secara stabil dan menghindari *overfitting*, dengan pembagian data 80% untuk pelatihan dan 20% untuk validasi.

Beberapa strategi optimisasi juga diterapkan, seperti *Early Stopping* untuk menghentikan proses pelatihan ketika akurasi validasi tidak lagi meningkat, *Reduce Learning Rate on Plateau* untuk menurunkan laju pembelajaran secara otomatis ketika performa stagnan, serta Model *Checkpoint* untuk menyimpan bobot terbaik selama proses pelatihan berlangsung.

Parameter lengkap dan konfigurasi pelatihan model disajikan pada Tabel 2 berikut:


Tabel 2. Parameter dan Konfigurasi Proses Pelatihan Model CNN

| Komponen | Konfigurasi/Nilai | Keterangan |
|-----------------------------|----------------------------------------|----------------------------------------------------------------------|
| <i>Optimizer</i> | Adam | Menyesuaikan laju pembelajaran secara adaptif. |
| <i>Learning Rate</i> | 0.0002 | Mengontrol kecepatan pembaruan bobot model. |
| <i>Loss Function</i> | <i>Sparse Categorical Crossentropy</i> | Cocok untuk klasifikasi multikelas dengan label numerik. |
| <i>Epoch</i> | 10 | Jumlah iterasi pelatihan penuh terhadap dataset |
| <i>Batch Size</i> | 16 | Jumlah citra yang di proses dalam setiap iterasi pelatihan. |
| <i>Early Stopping</i> | Aktif | Menghentikan pelatihan bila akurasi validasi stagnan. |
| <i>Reduce LR on Plateau</i> | Aktif | Menurunkan <i>learning rate</i> bila performa model tidak meningkat. |
| <i>Model Checkpoint</i> | Aktif | Menyimpan bobot terbaik berdasarkan akurasi validasi tertinggi. |
| Lingkungan Pelatihan | GPU dengan <i>mixed precision</i> | Mempercepat komputasi dan efisiensi memori |

Dengan konfigurasi tersebut, proses pelatihan dapat mencapai keseimbangan antara kecepatan konvergensi dan stabilitas performa model. Hasil pelatihan yang diperoleh kemudian dievaluasi menggunakan data validasi untuk memastikan kemampuan generalisasi model terhadap citra bunga yang belum pernah dilihat sebelumnya.

3.1. Hasil Pelatihan Model

Proses pelatihan model CNN menggunakan arsitektur *EfficientNet* dilakukan selama 10 *epoch* dengan pembagian data sebesar 80% untuk pelatihan dan 20% untuk validasi. Hasil pelatihan menghasilkan kurva *accuracy* dan *loss* yang ditampilkan pada Gambar 2.



Gambar 2. Kurva Akurasi dan *Loss* Pelatihan serta Validasi

Berdasarkan Gambar 2, nilai akurasi pelatihan meningkat secara konsisten dari 0,90 pada *epoch* pertama hingga mencapai 0,98 pada *epoch* ke-10. Akurasi validasi juga menunjukkan tren yang stabil di kisaran 0,93–0,94, yang menandakan bahwa model mampu belajar dengan baik tanpa mengalami *overfitting* yang signifikan.

Nilai *loss* pelatihan menurun dari 0,31 menjadi 0,04, sedangkan *loss* validasi relatif stabil di sekitar 0,22–0,25, menunjukkan bahwa model mencapai titik konvergensi yang optimal dan mampu melakukan generalisasi terhadap data baru dengan baik.

3.2. Evaluasi Model

Setelah proses pelatihan selesai, model terbaik disimpan dan diuji menggunakan data validasi sebanyak 3.438 citra bunga dari 19 kelas. Hasil evaluasi menunjukkan bahwa model memperoleh akurasi validasi akhir sebesar 98,05% dengan nilai *loss* akhir 0,0968.

Evaluasi dilakukan menggunakan metrik *precision*, *recall*, dan *F1-score*, sebagaimana disajikan dalam Tabel 3 berikut.

Tabel 3. Laporan Klasifikasi Model CNN pada 19 Kelas Bunga


| Kelas Bunga | Presisi | Recall | F1-Score | Support |
|-------------------------|---------|--------|----------|---------|
| <i>Astilbe</i> | 0.97 | 0.97 | 0.97 | 147 |
| <i>Bellflower</i> | 0.95 | 0.96 | 0.95 | 174 |
| <i>Black Eyed Susan</i> | 1.00 | 1.00 | 1.00 | 200 |
| <i>Calendula</i> | 0.99 | 0.95 | 0.97 | 195 |
| <i>California Poppy</i> | 0.98 | 0.98 | 0.98 | 204 |
| <i>Carnation</i> | 0.98 | 0.98 | 0.98 | 184 |
| <i>Common Daisy</i> | 0.99 | 0.98 | 0.99 | 196 |
| <i>Coreopsis</i> | 0.97 | 1.00 | 0.98 | 209 |
| <i>Daffodil</i> | 0.99 | 0.99 | 0.99 | 194 |
| <i>Dandelion</i> | 0.97 | 1.00 | 0.98 | 210 |
| <i>Iris</i> | 0.99 | 1.00 | 0.99 | 210 |
| <i>Lavender</i> | 0.98 | 0.86 | 0.91 | 100 |
| <i>Lotus</i> | 0.98 | 0.88 | 0.93 | 100 |
| <i>Magnolia</i> | 0.98 | 0.99 | 0.98 | 209 |
| <i>Orchid</i> | 0.99 | 0.98 | 0.98 | 97 |
| <i>Rose</i> | 0.99 | 1.00 | 0.99 | 199 |
| <i>Sunflower</i> | 1.00 | 1.00 | 1.00 | 205 |
| <i>Tulip</i> | 0.99 | 1.00 | 0.99 | 209 |
| <i>Water Lily</i> | 0.94 | 0.99 | 0.97 | 196 |

| Kelas Bunga | Presisi | Recall | F1-Score | Support |
|---------------------|---------|--------|----------|---------|
| <i>Common Daisy</i> | 0.98 | 0.98 | 0.98 | 204 |
| <i>Coreopsis</i> | 0.98 | 0.98 | 0.98 | 184 |
| <i>Daffodil</i> | 0.99 | 0.98 | 0.99 | 196 |
| <i>Dandelion</i> | 0.97 | 1.00 | 0.98 | 209 |
| <i>Iris</i> | 0.99 | 0.99 | 0.99 | 194 |

Berdasarkan hasil pada tabel, model menunjukkan performa yang sangat baik dengan rata-rata nilai *precision*, *recall*, dan *F1-score* sebesar 0,98. Beberapa kelas seperti *Black Eyed Susan*, *Sunflower*, dan *Iris* mencapai nilai sempurna (1,00) di semua metrik, sementara *Lavender* dan *Lotus* sedikit lebih rendah karena kemiripan warna dan bentuk dengan kelas bunga lain.

3.3. Analisis Confusion Matrix

Hasil prediksi model divisualisasikan menggunakan *confusion matrix* sebagaimana ditampilkan pada Gambar 3 berikut.




Gambar 3. Confusion Matrix Klasifikasi 19 Jenis Bunga

Dari Gambar 3 terlihat bahwa mayoritas nilai berada pada diagonal utama, yang menandakan bahwa model berhasil mengklasifikasikan sebagian besar citra dengan benar. Kesalahan kecil terjadi pada kelas *Lavender* dan *Lotus*, yang sebagian citranya terprediksi sebagai kelas lain.

Distribusi prediksi yang merata dan tingkat kesalahan yang rendah memperkuat temuan bahwa model *EfficientNet* memiliki kemampuan ekstraksi fitur yang baik terhadap bentuk, warna, dan tekstur bunga yang kompleks.

3.4. Implementasi dan Pengujian Sistem

Tahap implementasi dilakukan setelah model CNN berhasil dilatih dan dievaluasi. Tujuannya adalah agar model dapat digunakan secara langsung oleh pengguna melalui sistem berbasis web. Alur kerja model setelah diimplementasikan ditunjukkan pada Gambar 4.

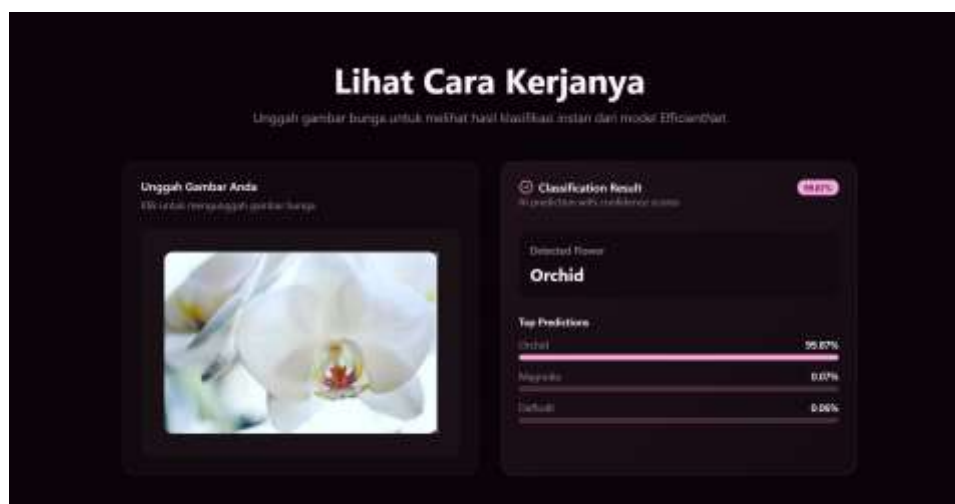


Gambar 4. Alur Kerja Model dan Integrasi Sistem Klasifikasi Bunga

Diagram tersebut menjelaskan bagaimana sistem beroperasi pada infrastruktur layanan berbasis web. Pengguna mengunggah citra bunga melalui antarmuka (*frontend*) yang dibangun menggunakan *Next.js*, kemudian citra tersebut dikirim sebagai *request* ke model CNN yang telah di-*deploy* pada platform *Hugging Face* sebagai *API inference endpoint*. Sistem kemudian memproses input, melakukan klasifikasi, dan mengembalikan hasil prediksi berupa nama bunga serta nilai probabilitasnya kepada pengguna sebagai *response*.

Setelah model selesai dilatih dan diuji, tahap berikutnya adalah implementasi penuh ke dalam sistem berbasis web. Model CNN yang telah di-*fine-tune* disimpan dalam format *.keras*, kemudian diunggah ke platform *Hugging Face Hub* agar dapat digunakan secara daring. Arsitektur sistem dikembangkan menggunakan *Next.js* untuk antarmuka web interaktif yang menghubungkan pengguna dengan model secara real-time.

Antarmuka sistem dirancang sederhana dan intuitif, memungkinkan pengguna untuk mengunggah gambar bunga dan memperoleh hasil klasifikasi secara instan. Tampilan hasil implementasi sistem dapat dilihat pada Gambar 5.



Gambar 5. Tampilan Hasil Implementasi Sistem Klasifikasi Bunga

Pada tampilan di atas, pengguna dapat mengunggah gambar bunga melalui menu “Unggah Gambar Anda”, kemudian sistem menampilkan hasil klasifikasi di sisi kanan dengan tingkat kepercayaan (*confidence score*). Contoh hasil pada Gambar 5 menunjukkan bahwa sistem berhasil mendeteksi bunga jenis *Orchid* dengan tingkat kepercayaan 99,87%, sedangkan prediksi lainnya adalah *Magnolia* (0,07%) dan *Daffodil* (0,06%). Dan hasil pengujian menunjukkan bahwa sistem mampu melakukan klasifikasi secara real-time dengan tingkat akurasi tinggi

4. DISCUSSION/CONSLUSION

4.1. KESIMPULAN

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, dapat disimpulkan bahwa penerapan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur *EfficientNet* mampu menghasilkan performa yang sangat baik dalam klasifikasi citra bunga multikelas. Model yang dikembangkan berhasil mencapai akurasi validasi sebesar 98,05% dengan nilai *loss* 0,0968, serta menunjukkan nilai presisi, *recall*, dan *F1-score* rata-rata sebesar 0,98.

Penerapan teknik *transfer learning* dan augmentasi data berkontribusi signifikan terhadap peningkatan kemampuan model dalam mengenali berbagai variasi warna, bentuk, dan tekstur bunga, sehingga mengurangi risiko *overfitting* serta meningkatkan kemampuan generalisasi. Implementasi model ke dalam sistem berbasis web juga menunjukkan hasil yang optimal, dengan tingkat kepercayaan klasifikasi mencapai 99,87% pada pengujian citra baru.

Secara keseluruhan, penelitian ini berhasil mencapai tujuan yang telah dirumuskan, yaitu menghasilkan sistem klasifikasi bunga otomatis berbasis CNN yang akurat, efisien, dan dapat dioperasikan secara real-time melalui platform berbasis cloud.

4.2. SARAN

Penelitian ini masih dapat dikembangkan lebih lanjut dengan memperluas jumlah kelas bunga dan menambahkan data dari berbagai kondisi pencahayaan serta latar belakang alami untuk meningkatkan *robustnes* model. Selain itu, dapat dilakukan eksplorasi terhadap arsitektur CNN lainnya seperti *Vision Transformer* (ViT) atau *ConvNeXt* untuk membandingkan performa dan efisiensi komputasi.

Dari sisi implementasi, integrasi dengan perangkat mobile atau *Internet of Things* (IoT) dapat menjadi langkah lanjutan agar sistem ini dapat digunakan secara langsung di lapangan untuk tujuan konservasi, identifikasi spesies tumbuhan, maupun edukasi botani interaktif.

DAFTAR PUSTAKA

- Anggara, J., Ryansyah, E., & Arif Dermawan, B. (2025). Implementasi Object Detection Dalam Klasifikasi Sampah Untuk Meningkatkan Efisiensi Pengelolaan Limbah. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(3), 4923–4930. <https://doi.org/10.36040/jati.v9i3.13813>
- Atila, Ü., Uçar, M., Akyol, K., & Uçar, E. (2020). Jo ur na l P re of. *Ecological Informatics*, 101182. <https://doi.org/10.1016/j.ecoinf.2020.101182>
- Barman, U., Sarma, P., Rahman, M., Deka, V., Lahkar, S., & Sharma, V. (2024). *ViT-SmartAgri: Vision Transformer and Smartphone-Based Plant Disease Detection for Smart Agriculture*.
- Borhani, Y., Khoramdel, J., & Najafi, E. (2022). OPEN A deep learning based approach for automated plant disease classification using vision transformer. *Scientific Reports*, 0123456789, 1–10. <https://doi.org/10.1038/s41598-022-15163-0>
- Chug, A., Singh, A. P., Singh, D., & Based, D. L. (2023). *Retraction Retracted: A Systematic Analysis of Machine Learning and Deep Learning Based Approaches for Plant Leaf Disease Classi fication: A Review. 2022*. <https://doi.org/10.1155/2022/3287561>
- Dan, D., Gestur, P., & Secara, T. (2023). *Deteksi dan pengenalan gestur tangan secara real-time menggunakan jaringan saraf tiruan konvolusional*. 9(2), 30–34.
- Hong, K., & Zhou, Y. (2025). *The pipelines of deep learning-based plant image processing*.
- Ibrahim, M. M., Rahmadewi, R., Nurpulaela, L., Teknik, F., & Karawang, U. S. (2023). *PENDETEKSIAN NOMINAL UANG PADA GAMBAR MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK: INTEGRASI METODE PRA- PEMROSESAN CITRA DAN KLASIFIKASI BERBASIS CNN*. 7(2), 1395–1400.
- Insan, J. (n.d.). *Sistem Pakar Pra-Diagnosa Penyakit Kulit dengan Metode Forward Chaining dan CNN dan Sains Data*.
- Ki, A., & Sharma, D. P. (2024). *Deep learning for medicinal plant species classi fication and recognition : a*

- systematic review. January*, 1–18. <https://doi.org/10.3389/fpls.2023.1286088>
- Min, B., Kim, T., & Shin, D. (2023). *applied sciences Data Augmentation Method for Plant Leaf Disease Recognition*. 1–17.
- Nugroho, A., K. D. A. W., & Fiolana, F. A. (2023). *Klasifikasi Helm Keselamatan Menggunakan Metode Convolutional Neural Network (CNN)*. 05(02), 94–102.
- Saleem, M. H., & Potgieter, J. (2020). *Plant Disease Classification : A Comparative Evaluation of Convolutional Neural Networks and Deep Learning Optimizers*.
- Sun, Y., Ning, L., Zhao, B., & Yan, J. (2024). *applied sciences Tomato Leaf Disease Classification by Combining EfficientNetv2 and a Swin Transformer*.
- Tan, M., & Le, Q. V. (2021). *EfficientNetV2 : Smaller Models and Faster Training*.
- Zhang, J., Zhou, H., Liu, K., & Xu, Y. (2025). *ED-Swin Transformer : A Cassava Disease Classification Model Integrated with UAV Images*. 1–16.
- Pratiwi, H. A., Cahyanti, M., & Lamsani, M. (2021). IMPLEMENTASI DEEP LEARNING FLOWER SCANNER MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK. *Sebatik*, 25(1), 124–130. <https://doi.org/10.46984/sebatik.v25i1.1297>
- Predianto, E., & Sutomo, B. (2024). KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) MENGGUNAKAN METODE REGION-BASED CONVOLUTIONAL NEURAL NETWORK (R-CNN). *Jurnal Pendidikan Teknologi Informasi*, 8(2), 1–15. <https://jurnal.ar-raniry.ac.id/index.php/cyberspace/article/view/25441>
- Rumui, N., Mualo, A., Rahayaan, J., Batjo, L., Mokansi, M., Informatika, M., Negeri Fakkak Jl Imam Bonjol, P., Fakkak, K., Fakkak, K., Barat, P., Sam Ratulangi Jl Kampus UNSRAT Bahu, U., Malalayang, K., Manado, K., & Utara, S. (2025). *JURNAL INFORMATIK Edisi ke-21, Nomor 1*. <https://ejournal.upnvj.ac.id/informatik/article/view/11105/3602>
- Sibarani, J. S., Tumpal Damanik, S., Nurkhalizah, R., Mulyana, S., & Nasution, B. (2023). Klasifikasi Tanaman Hias Menggunakan Algoritma Convolution Neural Network. In *Journal of Information Technology Ampere* (Vol. 4, Issue 3). <https://journal-computing.org/index.php/journal-ita/index>