

PENERAPAN METODE CNN BERBASIS ARSITEKTUR *MOBILENET* PADA KLASIFIKASI CITRA BUNGA (Famili *Asteraceae*)

Agis Pangestu¹, Denny Pribadi², Saeful Bahri³, Satia Suhada⁴

^{1,2,3,4}Universitas Bina Sarana Informatika Kampus Kota Sukabumi

e-mail: agispangestu11@gmail.com, denny.dpi@bsi.ac.id, saeful.sel@bsi.ac.id,
satia.shq@bsi.ac.id

Abstraksi

Penelitian ini bertujuan untuk menerapkan model klasifikasi citra bunga dari famili Asteraceae menggunakan metode Convolutional Neural Network (CNN) berbasis arsitektur MobileNet. Latar belakang penelitian ini adalah keanekaragaman bunga dalam famili Asteraceae yang menyulitkan proses klasifikasi manual. Dengan menggunakan teknologi pengolahan citra digital, klasifikasi otomatis diharapkan dapat memberikan hasil yang lebih akurat dan efisien. Dataset yang digunakan terdiri dari 2.600 citra bunga yang dikumpulkan dari berbagai genus dalam famili Asteraceae seperti Ageratum, Aster, Chrysanthemum, Cornflower, Cosmos, Dahlia, Daisy, Marigold, dan Sunflower. Penelitian ini menggunakan metode CNN dengan arsitektur MobileNet yang dikenal memiliki kinerja baik dalam klasifikasi citra dengan ukuran model yang lebih kecil dan efisien. Hasil penelitian menunjukkan bahwa metode CNN berbasis arsitektur MobileNet mampu mengklasifikasikan citra bunga dari famili Asteraceae dengan akurasi sebesar 90.51%. Implementasi model ini diharapkan dapat berkontribusi dalam pengembangan teknologi pengenalan tanaman yang berguna untuk keperluan budidaya, penelitian, dan edukasi.

Kata Kunci: Bunga, Asteraceae, Convolutional Neural Network, Klasifikasi Citra, Mobilenet

Abstract

This study aims to apply an image classification model for flowers from the Asteraceae family using the Convolutional Neural Network (CNN) method based on the MobileNet architecture. The background of this study is the diversity of flowers in the Asteraceae family, which makes manual classification difficult. By using digital image processing technology, automatic classification is expected to provide more accurate and efficient results. The dataset used consists of 2,600 flower images collected from various genera in the Asteraceae family, such as Ageratum, Aster, Chrysanthemum, Cornflower, Cosmos, Dahlia, Daisy, Marigold, and Sunflower. This study uses the CNN method with the MobileNet architecture, which is known to perform well in image classification with a smaller and more efficient model size. The results show that the MobileNet-based CNN method is capable of classifying images of flowers from the Asteraceae family with an accuracy of 90.51%. The implementation of this model is expected to contribute to the development of plant recognition technology that is useful for cultivation, research, and education purposes.

Keywords: Flower, Asteraceae, Convolutional Neural Network, Image Classification, Mobilenet

1. Pendahuluan

Famili Asteraceae adalah salah satu kelompok tumbuhan berbunga terbesar di dunia, terdiri dari lebih dari 1.100 genus dan hampir 20.000 spesies yang menyebar di berbagai wilayah dengan iklim sedang, dingin, maupun subtropis (Audya et al., 2023). Variasi morfologi bunga dalam famili ini sangat besar, mulai dari warna, bentuk, hingga ukuran, sehingga proses klasifikasi dan identifikasi secara manual menjadi sulit, terutama bagi orang yang tidak

memiliki pengetahuan khusus. (Azzaroiha et al., 2022).

Tantangan tersebut mendorong penggunaan teknologi pengolahan citra digital untuk membantu mengklasifikasikan tumbuhan. Salah satu metode yang banyak digunakan adalah Convolutional Neural Network (CNN), yang terbukti efektif dalam mengenali pola visual pada data citra (Rahmawati dan Sulistiyowati, 2021).

Penelitian sebelumnya menunjukkan bahwa pilihan arsitektur CNN sangat berpengaruh terhadap tingkat akurasi.

Misalnya, CNN standar hanya mencapai akurasi sebesar 62%, namun dengan menggunakan arsitektur VGG16, akurasi bisa meningkat hingga 80% (Husodo et al., 2023).

Dalam penelitian ini, digunakan arsitektur MobileNet untuk mengklasifikasikan citra bunga Asteraceae. MobileNet dipilih karena dirancang untuk menghasilkan model yang ringan, efisien dalam penggunaan sumber daya komputer, namun tetap memiliki akurasi tinggi. Teknik depthwise separable convolution dalam MobileNet mampu mengurangi jumlah parameter dan mempercepat proses pelatihan, sehingga lebih hemat dibandingkan arsitektur CNN tradisional. Keunggulan ini menjadikan MobileNet sangat cocok untuk klasifikasi bunga Asteraceae yang memiliki tingkat variasi morfologi tinggi, meskipun menggunakan dataset berukuran menengah. (Alfandi Mualo et al., 2023).

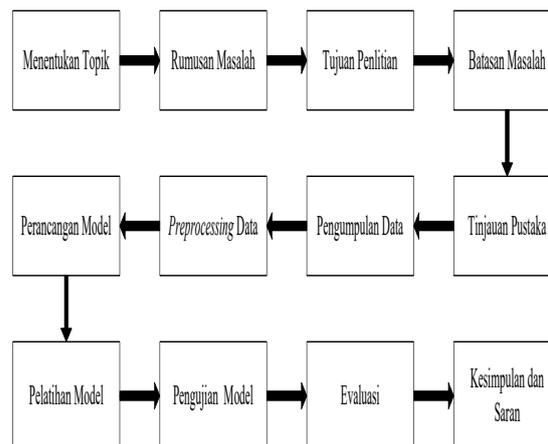
Dataset yang digunakan dalam penelitian ini terdiri dari 2.600 gambar bunga dari 9 genus dalam famili Asteraceae, yaitu Ageratum, Aster, Chrysanthemum, Cornflower, Cosmos, Dahlia, Daisy, Marigold, dan Sunflower. Dengan penerapan MobileNet, diharapkan diperoleh model klasifikasi yang efisien sekaligus akurat, sehingga bisa menjadi solusi praktis dalam identifikasi bunga dari famili Asteraceae.

2. Metode Penelitian

2.1. Proses dan Langkah Penelitian

Penelitian ini dilakukan dengan tujuan untuk menerapkan metode *Convolution Neural Network* (CNN) berbasis arsitektur *MobileNet* pada klasifikasi citra bunga famili *Asteraceae*. Proses penelitian ini terdiri dari beberapa tahapan sebagai berikut:

A. Kerangka Penelitian



Gambar 2.1. Kerangka Penelitian

1. Menentukan Topik

Topik penelitian ini adalah penerapan metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNet* untuk klasifikasi citra bunga dari famili *Asteraceae*.

2. Rumusan Masalah

Mengidentifikasi rumusan permasalahan yang ada dalam penelitian ini yaitu. Bagaimana penerapan metode *Convolution Neural Network* (CNN) untuk klasifikasi citra bunga famili *Asteraceae* dengan arsitektur *MobileNet*.

3. Tujuan Penelitian

Menentukan tujuan dari penelitian yang akan dicapai yaitu menerapkan metode CNN berbasis arsitektur *MobileNet* pada klasifikasi citra bunga dari famili *Asteraceae* dan mengetahui tingkat akurasi yang diperoleh dari model.

4. Batasan Masalah

Menentukan batasan masalah dalam penelitian yaitu hanya ada 9 kelas citra bunga yang akan diklasifikasi dari famili *Asteraceae*.

5. Tinjauan Pustaka

Melakukan proses pengumpulan, membaca, menganalisis, dan menyusun informasi dari berbagai sumber tertulis buku, jurnal dan laporan penelitian yang berkaitan dengan topik penelitian.

6. Pengumpulan Data

Pada tahap ini data yang dikumpulkan yaitu berupa gambar bunga, yang diambil dari *Kaggle* yang merupakan data sekunder. Gambar terdiri dari 299 jenis bunga yang akan dipilih hanya 9 kelas

bunga yang teridentifikasi sebagai bunga dari tanaman famili *Asteraceae*.

7. Preprocessing Data

Pada tahap *preprocessing* dataset ini kemudian diproses untuk menghilangkan *noise*, memastikan resolusi gambar yang konsisten dan normalisasi juga diterapkan untuk memastikan bahwa data berada dalam rentang yang sesuai untuk dimasukkan ke dalam metode CNN. Setelah itu, dataset akan dibagi menjadi set pelatihan, validasi, dan pengujian dengan proporsi yang tepat untuk memastikan evaluasi model yang akurat.

8. Perancangan Model

Pada penelitian ini algoritma yang digunakan adalah metode *Convolutional Neural Network* (CNN) lalu dikembangkan dengan arsitektur *MobileNet*.

9. Pelatihan Model

Melakukan pelatihan dataset menggunakan metode CNN menggunakan arsitektur *MobileNet* dengan dataset yang telah diproses, serta melakukan validasi untuk memastikan dengan metode dan arsitektur tersebut dapat bekerja dengan baik.

10. Pengujian Model

Melakukan pengujian model yang sudah dilatih untuk memastikan performa yang konsisten.

11. Evaluasi model

Evaluasi model dilakukan menggunakan metrik akurasi, *precision*, *recall* dan *F1 score* untuk memastikan bahwa model tersebut dapat digunakan secara akurat dan efektif.

12. Kesimpulan dan Saran

Pada tahap ini merangkum seluruh isi penelitian dan memberikan rekomendasi untuk pengembangan penelitian lebih lanjut.

Pemilihan arsitektur *MobileNet* dalam penelitian ini didasarkan pada pertimbangan efisiensi dan efektivitas dalam proses mengklasifikasikan gambar bunga dari keluarga *Asteraceae*. *MobileNet* adalah salah satu jenis CNN yang dirancang khusus untuk menghasilkan

model yang ringan dan membutuhkan komputasi yang rendah, tanpa mengorbankan akurasi secara signifikan. Hal ini dimungkinkan karena *MobileNet* menggunakan teknik konvolusi *depthwise separable*, yaitu membagi proses konvolusi menjadi dua tahap, sehingga bisa mengurangi jumlah parameter dan operasi komputasi secara besar-besaran dibandingkan dengan konvolusi biasa.

Kelebihan lain dari *MobileNet* adalah kemampuannya berjalan secara efisien pada perangkat yang memiliki sumber daya terbatas, seperti *smartphone*, perangkat IoT, atau sistem komputasi tepi.

Dengan demikian, model yang dihasilkan tidak hanya akurat, tetapi juga bisa digunakan secara praktis di berbagai platform dengan kemampuan komputasi terbatas.

Selain itu, *MobileNet* terbukti memiliki akurasi yang cukup baik jika dibandingkan dengan arsitektur CNN yang lebih rumit, seperti VGG16 atau ResNet.

Meski model-model tersebut bisa memberikan akurasi yang tinggi, kebutuhan komputasi dan ukuran model yang besar seringkali menjadi hambatan dalam penerapan nyata. *MobileNet* menawarkan solusi yang seimbang, yaitu tetap menjaga performa klasifikasi gambar yang baik sekaligus lebih hemat dalam penggunaan sumber daya.

Tidak hanya itu, *MobileNet* juga mendukung pendekatan *transfer learning*, di mana bobot yang sudah dilatih dari dataset besar seperti *ImageNet* bisa digunakan.

Dengan cara ini, proses pelatihan model menjadi lebih cepat, serta hasil klasifikasi pada dataset bunga *Asteraceae* bisa ditingkatkan. Oleh karena itu, *MobileNet* dianggap sebagai arsitektur yang paling sesuai untuk penelitian ini, mengingat kebutuhan akan model yang efisien, akurat, dan bisa diaplikasikan secara luas.

B. Sumber Data

Data yang digunakan dalam penelitian ini bersumber dari data yang tersedia *online* atau termasuk ke dalam sekunder, seperti yang disediakan oleh salah satu *platform* yaitu *Kaggle*. Data yang diambil bukan

dataset *private*, melainkan data publik. Data yang dipilih berisi informasi terkait 299 citra bunga dengan format *Joint Photographic Experts Group* (JPEG) (Cretu dan Iftene, 2021).

C. Pengambilan Data

Dataset dipilih secara khusus berdasarkan relevansinya dengan tujuan penelitian yaitu pemodelan dan klasifikasi citra bunga dari famili *Asteraceae*. Ada 9 kelas citra bunga yang diambil dan sudah teridentifikasi kedalam famili *Asteraceae*. Dengan tujuan untuk mendapatkan data yang sesuai dengan penelitian yaitu membuat model *machine learning* menggunakan metode CNN.

D. Teknik Pengumpulan Data

Data pada penelitian ini bersumber dari platform *Kaggle*, kemudian dikumpulkan untuk dataset dalam format *Joint Photographic Experts Group* (JPEG). Berikut adalah prosedur pengumpulan sebagai berikut:

1. Mengunduh dataset setelah mendaftar dan menyetujui ketentuan penggunaan.
2. Data dipilih untuk kebutuhan yang akan digunakan dalam penelitian ini. Ada 9 citra bunga yang terdiri dari: *Ageratum*, *Aster*, *Chrysanthemum*, *Cornflower*, *Cosmos*, *Dahlia*, *Daisy*, *Marigold* dan *Sunflower*.
3. Pembersihan data citra bunga yang kurang relevan, agar pembagian dataset sesuai.

3.2. Metode Pengolahan dan Analisis Data

A. Dataset

Pada Penelitian ini dataset merupakan data sekunder yang dikumpulkan dalam format *Joint Photographic Experts Group* (JPEG) dimana data diperoleh dengan mengunduh dari platform *Kaggle*. Dataset yang dikumpulkan sebanyak 2.600 dataset, yang terdiri dari 9 kelas bunga dari famili *Asteraceae* yang kemudian di dimasukkan sebagai dataset pelatihan dan pengujian pada *Google Drive*.

B. Perancangan Model Klasifikasi

Dalam tahap perancangan model klasifikasi menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur

MobileNet yang telah dimodifikasi untuk mengoptimalkan kinerja pada dataset.

C. Preprocessing Data

Preprocessing data merupakan langkah penting tujuannya adalah untuk mempersiapkan data citra yang sesuai dengan format dan persyaratan masukan metode CNN, untuk meningkatkan performa dan akurasi model. Berikut adalah beberapa detail dari *preprocessing* data:

1. Mengubah Ukuran dan Format Gambar
Mengubah ukuran citra menjadi ukuran 224x224 piksel sehingga semua citra memiliki ukuran yang sama dengan warna RGB. Selain itu juga format gambar diubah dari format aslinya *jpeg* ke format yang kompatibel dengan metode CNN
2. Normalisasi Nilai Piksel
Melakukan normalisasi nilai piksel suatu gambar untuk memastikan bahwa semua nilai piksel berada dalam rentang yang sama, misalnya dari 0 hingga 1. Teknik normalisasi yang umum digunakan adalah normalisasi min-max dan normalisasi standar. Normalisasi membantu metode CNN untuk fokus pada fitur – fitur penting pada gambar dan meningkatkan akurasi klasifikasi.
3. Pembagian Data
Membagi kumpulan dataset yang sudah diproses sebelumnya menjadi set pelatihan, set validasi dan set pengujian. Set pelatihan digunakan untuk melatih metode CNN, set validasi digunakan untuk melacak performa model selama pelatihan dan set pengujian digunakan untuk mengevaluasi kinerja akhir model. *Presentase* pembagian data yang umum digunakan adalah 70% untuk set pelatihan, 20% untuk seluruh proses validasi, dan 10% untuk set pengujian.

D. Evaluasi

Data yang diolah akan dianalisis untuk menguji hipotesis penelitian dengan metrik evaluasi sebagai berikut:

1. Confusion Matrix

Confusion Matrix adalah tabel yang digunakan untuk mengevaluasi performa model klasifikasi *Machine Learning*. Yang berfungsi untuk memvisualisasikan keakuratan model dengan menunjukkan berapa banyak prediksi yang benar dan

salah. Ada empat istilah penting terkait dengan *Confusion Matrix*:

- True Positive (TP): ini adalah kasus ketika model memprediksi kelas positif dengan benar.
- True Negative (TN): ini adalah kasus ketika model memprediksi kelas negatif dengan benar.
- False Positive (FP): Ini adalah kasus ketika model salah memprediksi kelas positif (juga dikenal sebagai kesalahan Tipe I).
- False Negative (FN): Ini adalah kasus ketika model salah memprediksi kelas negatif (juga dikenal sebagai kesalahan tipe II).

2. Akurasi

Akurasi adalah metrik paling umum yang menunjukkan persentase prediksi benar yang dibuat model di seluruh sampel data.

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

3. Precision

Precision menunjukkan seberapa akurat prediksi positif model. Dengan kata lain, berapa persentase data positif yang benar-benar positif.

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

4. Recall

Recall menunjukkan kecukupan prediksi positif model tersebut. Dengan kata lain, berapa persentase data positif yang berhasil diprediksi oleh model.

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

5. F1-score

F1-score adalah rata-rata harmonis antara *precision* dan *recall*, yang dihitung untuk menyeimbangkan kedua ukuran tersebut. *F1-score* sering digunakan ketika kita ingin mempertimbangkan *precision* dan *recall* secara bersamaan.

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

3. Hasil dan Pembahasan

3.1. Hasil Penelitian

Dalam tahap ini hasil disajikan secara terstruktur dan logis menggunakan teks, tabel, dan gambar. Data yang disajikan mencakup hasil evaluasi kinerja model CNN dengan arsitektur *MobileNet*.

A. Dataset

Dataset yang dikumpulkan sebanyak 2.600 dataset citra bunga dari famili *Asteraceae* masing - masing kelas ada 300 citra bunga yang akan digunakan dalam penelitian ini. Ada 9 citra bunga yang terdiri dari *Ageratum*, *Aster*, *Chrysanthemum*, *Cornflower*, *Cosmos*, *Dahlia*, *Daisy*, *Marigold* dan *Sunflower*.

Tabel 3.1. Jumlah Dataset

No	Nama Kelas	Jumlah
1	<i>Ageratum</i>	300 Citra
2	<i>Aster</i>	300 Citra
3	<i>Chrysanthemum</i>	300 Citra
4	<i>Cornflower</i>	300 Citra
5	<i>Cosmos</i>	300 Citra
6	<i>Dahlia</i>	300 Citra
7	<i>Daisy</i>	300 Citra
8	<i>Marigold</i>	300 Citra
9	<i>Sunflower</i>	300 Citra

Pada Tabel 3.2 merupakan sampel citra dengan total 9 kelas citra bunga dari famili *Asteraceae* sebagai berikut:

Tabel 3.2. Sampel Citra

No	Nama Kelas	Citra
1	<i>Ageratum</i>	
2	<i>Aster</i>	
3	<i>Chrysanthemum</i>	

4	Cornflower	
5	Cosmos	
6	Dahlia	
7	Daisy	
8	Marigold	
9	Sunflower	

B. Preprocessing

Fungsi *resize* pada citra diterapkan dalam tahap *preprocessing*. Tahapan ini mengubah ukuran citra pada dataset diubah menjadi berukuran 224x224 piksel dan dinormalisasi dengan skala 1./255, yang berarti nilai pikselnya diubah dari rentang [0, 255] menjadi [0, 1].



(a) (b)
Gambar 3.1. (a) sebelum preprocessing (b) sesudah preprocessing

C. Split Data

Pada *split* data dataset dibagi menjadi 3 bagian, pembagian dataset tersebut yaitu awalnya 2600 citra dibagi menjadi data training 83.08% dan data testing 16.92%, yaitu 2.160 citra menjadi data training dan 440 citra menjadi data testing. Kemudian pada data training dibagi lagi untuk data validasi yaitu 20% atau 432 citra dan data training 80% atau 1.728 citra. Jadi total pembagian dataset tersebut menjadi 66.46% data training, 16.92% data testing, dan 16.62% data validasi, yaitu 1.728 data training, 440 data testing, serta 432 data validasi.

Tabel 3.3. Proses Split Data

No	Jenis Data	Presentase	Jumlah
1	Train	66.46%	1.728
2	Validasi	16.62%	432
3	Test	16.92%	440

```

Model: "sequential_2"
Layer (type)                Output Shape                 Param #
-----
mobilenet_1.00_224 (Func    (None, 7, 7, 1024)          3228864
tional)
global_average_pooling2d_2  (None, 1024)                 0
(GlobalAveragePooling2D)
dense_2 (Dense)              (None, 9)                    9225
-----
Total params: 3238089 (12.35 MB)
Trainable params: 9225 (36.04 KB)
Non-trainable params: 3228864 (12.32 MB)

```

Jumlah	2.600
--------	-------

D. Perancangan Model Klasifikasi

Arsitektur yang digunakan pada penelitian ini yaitu *MobileNet*. Pada arsitektur ini dimulai dengan lapisan konvolusi pertama kemudian diikuti dengan 13 lapisan dari lapisan *depthwise convolution*, lapisan *pointwise convolution*. Fungsi aktivasi *Batch normalization* (BN) dan *Rectified Linear Unit* (ReLU) diterapkan setelah setiap lapisan konvolusi *depthwise* dan *pointwise*. Fungsi ini digunakan untuk membuat jaringan lebih cepat dan stabil. Selanjutnya model ini dibangun secara *Sequential* dengan memanfaatkan model

yang sudah terlatih sebelumnya (*base_model*) sebagai fondasinya.

Setelah itu, output dari base model diratakan secara *global* menggunakan lapisan *GlobalAveragePooling2D* untuk menghasilkan representasi fitur yang lebih padat. Terakhir, sebuah lapisan *Dense* dengan 9 neuron dan fungsi aktivasi *Softmax* ditambahkan untuk melakukan klasifikasi. Lapisan *dense* ini akan menghasilkan probabilitas untuk masing-masing dari 9 kelas. Proses kompilasi model mengatur bagaimana model akan dilatih. *Optimizer* Adam dipilih untuk memperbarui bobot model secara efisien, sementara fungsi kehilangan *categorical_crossentropy* digunakan untuk menghitung selisih antara prediksi model dan label yang sebenarnya. Metrik *accuracy* akan digunakan untuk mengukur kinerja model selama pelatihan dan evaluasi.

Proses selanjutnya yaitu *output*, menampilkan hasil dari klasifikasi yang telah dilakukan berdasarkan kelas yaitu, *Ageratum*, *Aster*, *Chrysanthemum*, *Cornflower*, *Cosmos*, *Dahlia*, *Daisy*, *Marigold* dan *Sunflower*. Total parameter setelah model arsitektur *MobileNet* yang telah dimodifikasi menjadi 3238089 dengan *Trainable params* 9225 dan *Non-trainable params* 3.228.864. Sehingga membuat model ini hanya memerlukan lebih sedikit waktu komputasi.

Gambar 3.2. Proses Klasifikasi

Pada Gambar 3.2 menunjukkan model klasifikasi citra menggunakan arsitektur *MobileNet* yang sudah terlatih sebelumnya sebagai dasar. Model ini kemudian dimodifikasi dengan menambahkan lapisan *global average pooling* untuk mereduksi dimensi fitur dan lapisan *dense* untuk melakukan klasifikasi. Lapisan *dense* inilah yang akan menghasilkan prediksi kelas untuk gambar *input*. Model ini telah dikompilasi dengan menggunakan optimizer *Adam* dan fungsi *loss categorical_crossentropy* untuk proses pelatihan. Hasil *summary* menunjukkan bahwa sebagian besar *parameter* model berasal dari lapisan *MobileNet* yang sudah terlatih, sementara *parameter* yang dapat dilatih sebagian besar berada pada lapisan *dense*. Dengan demikian, model ini dapat memanfaatkan pengetahuan yang telah dipelajari oleh *MobileNet* pada dataset

yang sangat besar untuk melakukan tugas klasifikasi citra dengan lebih baik.

E. Pelatihan Model

Pada proses *training* dataset model dilatih dengan menggunakan dataset *train* yang sudah disiapkan sebelumnya oleh *train_generator*. Model akan terus belajar dan memperbaiki diri selama 50 *epoch* dan jumlah *batch size* sebanyak 16 yang berarti akan memproses 16 citra dalam setiap *batch*. Kemudian kinerja model akan dievaluasi menggunakan data validasi di setiap iterasi untuk menghindari *overfitting*.

F. Pengujian Model

Mengevaluasi model pada tiga jenis data dari data pelatihan, data validasi dan data pengujian. Evaluasi pada data pelatihan memberikan gambaran dasar tentang kemampuan model. Evaluasi pada data validasi digunakan untuk mendeteksi *overfitting*, yaitu kondisi di mana model terlalu menghafal data pelatihan sehingga tidak dapat menggeneralisasi ke data baru. Evaluasi pada data pengujian memberikan gambaran paling akurat tentang kinerja model.

Selanjutnya akan mendapatkan pemahaman yang lebih mendalam untuk kinerja model pada data yang belum pernah dilihat sebelumnya. Dengan membandingkan label yang sebenarnya (*true*) dengan label yang diprediksi (*predict*), Yang berarti dapat mengidentifikasi kesalahan yang sering dilakukan oleh model dan melakukan perbaikan jika diperlukan. Kemudahan memvisualisasikan kinerja model klasifikasi dan mengidentifikasi area di mana model mungkin mengalami kesulitan dalam tahap pengujian menggunakan *Normalized Confusion Matrix*.

G. Evaluasi Model

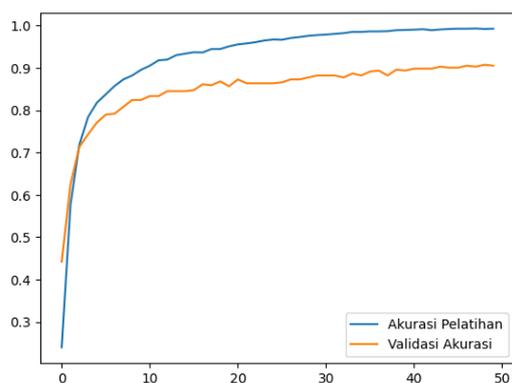
Pada tahap ini model akan dievaluasi keseluruhan. menentukan label kelas yang benar dan prediksi dari model menggunakan library *scikit-learn*. Selanjutnya menghitung *accuracy*, *precision*, *recall*, dan *F1-score*. Akurasi (*accuracy*) menunjukkan proporsi prediksi yang benar, presisi (*precision*) mengukur proporsi prediksi positif yang benar, *recall* mengukur proporsi contoh positif yang diprediksi dengan benar, dan *F1-score*

adalah rata-rata harmonik antara presisi dan recall.

3.2. Hasil Pengujian

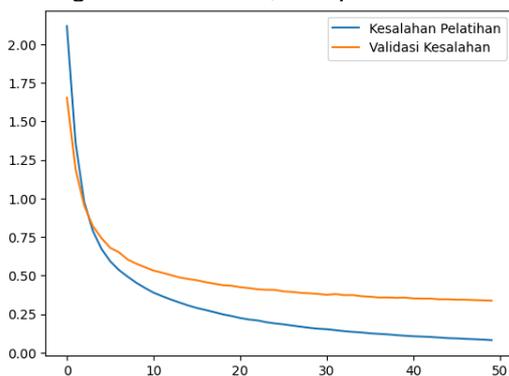
A. Hasil Pelatihan Model

Pada proses pelatihan terhadap model yang sudah dibuat dengan jumlah *epoch* 50 dan jumlah *batch size* 16. Kemudian pada Gambar 3.2 mengevaluasi hasil dari akurasi validasi dan akurasi *training*. Pada Gambar 3.3 evaluasi dari *loss* validasi dan *loss* training.



Gambar 3.3. Plot Akurasi Validasi dan Akurasi Pelatihan

Pada Gambar 3.2 merupakan grafik antara hasil akurasi data validasi dan akurasi data pelatihan. Hasil akurasi ini diambil dengan jumlah *epoch* 50. Dapat dilihat pada gambar grafik bahwa akurasi validasi dan akurasi *training* terus mengalami kenaikan disetiap *epoch* nya. Akurasi pada epoch 50 yaitu 99,25% pada training dan akurasi 90,51% pada validasi.



Gambar 3.4. Plot loss data validasi dan loss data pelatihan

Pada Gambar 3.3 merupakan grafik antara *loss* data validasi dan *loss* data pelatihan. Hasil dari nilai *loss* ini diambil dengan jumlah epoch 50. Dapat dilihat pada gambar grafik bahwa nilai *loss* validasi dan *loss* training terus mengalami penurunan disetiap epoch nya atau nilai

loss semakin kecil ini menunjukkan bahwa performa dari model yang digunakan memiliki kinerja yang bagus. *Loss* pada epoch 50 yaitu 0,0814 pada training dan *loss* 0,3372 pada validasi.

B. Hasil Pengujian Model

Pada tahap pengujian akan mengevaluasi model pada tiga jenis data dari data pelatihan, data validasi dan data pengujian. hasil dari akurasi dan nilai *loss* terhadap 50 jumlah epoch dan jumlah *batch size* 16 yang kemudian memvisualisasikan hasil prediksi benar dari salah satu citra bunga dari model dan memvisualisasikan hasil label benar dan label prediksi dalam bentuk *Normalized Confusion Matrix*.

Tabel 3.4. Perbandingan Nilai Akurasi dan Loss

Data	Akurasi	Nilai Loss
Data Train	0.9936	0.0792
Data Validasi	0.9051	0.3372
Data Test	0.9296	0.2602

Pada tabel 4.4 menunjukan hasil evaluasi model pada berbagai dataset. Pada dataset pelatihan (*train*), model mencapai nilai *loss* sebesar 7.92% dengan akurasi 99.36%, menunjukkan bahwa model sangat efektif dalam mengenali pola selama pelatihan. Pada dataset validasi, model menunjukkan nilai *loss* sebesar 33.72% dengan akurasi 90.51%, yang mengindikasikan bahwa meskipun model mengalami penurunan performa dibandingkan dengan dataset pelatihan, model masih cukup baik dalam menggeneralisasi data yang tidak terlihat selama pelatihan. Terakhir, pada dataset pengujian (*test*), model mencapai nilai *loss* sebesar 26.02% dengan akurasi 92.96%, menunjukkan bahwa model mempertahankan performa yang baik saat diuji dengan data baru. Secara keseluruhan, model ini menunjukkan akurasi yang sangat baik di semua dataset, meskipun ada peningkatan nilai *loss* dari



pelatihan ke validasi dan pengujian.

Gambar 3.5. Hasil Prediksi

Dari hasil yang ditampilkan pada Gambar 3.5, dapat disimpulkan bahwa model klasifikasi ini bekerja dengan sangat baik dalam mengidentifikasi bunga *Ageratum* pada dataset yang diberikan. Model ini memberikan probabilitas yang sangat tinggi untuk kelas *Ageratum* dan semua prediksinya benar.

Tabel 3.5. Normalized Confusion Matrix

		Label Prediksi								
		Ageratum	Aster	Chrysanthemum	Cornflower	Cosmos	Dahlia	Daisy	Marigold	Sunflower
Label Benar	Ageratum	0.98	0.00	0.00	0.02	0.00	0.00	0.00	0.00	0.00
	Aster	0.00	0.92	0.00	0.02	0.03	0.00	0.02	0.00	0.02
	Chrysanthemum	0.02	0.00	0.85	0.00	0.02	0.05	0.00	0.07	0.00
	Cornflower	0.00	0.03	0.00	0.93	0.00	0.00	0.03	0.00	0.00
	Cosmos	0.00	0.02	0.00	0.00	0.92	0.00	0.05	0.02	0.00
	Dahlia	0.00	0.03	0.02	0.00	0.00	0.95	0.00	0.00	0.00
	Daisy	0.00	0.03	0.02	0.00	0.00	0.00	0.95	0.00	0.00
	Marigold	0.00	0.00	0.03	0.00	0.00	0.00	0.05	0.92	0.00
	Sunflower	0.00	0.00	0.02	0.00	0.02	0.00	0.02	0.00	0.95

Berdasarkan Tabel 4.5 matriks kebingungan yang dinormalkan (*Normalized Confusion Matrix*), model menunjukkan performa tinggi dengan akurasi sebagai berikut: *Ageratum* 98%, *Aster* 92%, *Chrysanthemum* 85%, *Cornflower* 93%, *Cosmos* 92%, *Dahlia* 95%, *Daisy* 95%, *Marigold* 92%, dan *Sunflower* 95%. Secara keseluruhan, model ini menunjukkan kinerja yang baik dalam mengklasifikasikan berbagai jenis bunga.

C. Evaluasi Model

Secara umum, model MobileNet yang digunakan dalam penelitian ini berjalan cukup baik dalam membedakan berbagai jenis bunga dari keluarga Asteraceae. Kebanyakan kelas memiliki tingkat akurasi yang tinggi, dan jumlah kesalahan klasifikasi juga tidak terlalu besar. Ini menunjukkan bahwa arsitektur MobileNet mampu menangkap fitur-fitur visual yang penting meskipun jumlah parameter dan tingkat kompleksitasnya lebih rendah dibandingkan model CNN lain yang ukurannya lebih besar.

Namun, hanya mengandalkan akurasi belum cukup untuk melihat performa model secara lengkap. Akurasi hanya menunjukkan seberapa besar prediksi yang benar dibandingkan semua prediksi yang dibuat, tanpa memperhatikan seimbang tidaknya jumlah sampel per kelas. Dalam penelitian ini, jumlah gambar untuk setiap kelas tidak sama; beberapa spesies bunga memiliki lebih banyak gambar daripada yang lain. Jika hanya melihat akurasi, model mungkin terlihat bagus meskipun sebenarnya lebih miring menyukai kelas yang memiliki data lebih banyak.

Oleh karena itu, metrik F1-score digunakan sebagai ukuran yang lebih lengkap. F1-score adalah rata-rata harmonis dari precision dan recall. Precision mengukur seberapa tepat prediksi kelas yang diberikan, sementara recall mengukur seberapa banyak sampel yang benar-benar diidentifikasi oleh model dari kelas tersebut. Dengan demikian, F1-score lebih cocok untuk mengevaluasi kinerja model dalam klasifikasi multikelas, terutama ketika data tidak seimbang.

Sebagai contoh, pada kelas *Chrysanthemum*, model memiliki akurasi yang tinggi, tapi F1-score justru lebih rendah dibandingkan kelas lain. Ini menandakan adanya ketidakseimbangan antara precision dan recall: model sering mengklasifikasikan bunga lain sebagai *Chrysanthemum* (salah positif), sekaligus melewatkan beberapa *Chrysanthemum* yang sebenarnya ada (salah negatif). Jika hanya melihat akurasi, fenomena ini tidak akan terlihat.

Tabel 3.6. Evaluasi Akhir Model

Metrik	Nilai
Akurasi	91%
Presisi	92 %
Recall	97%
F1-Score	95%

Berdasarkan hasil evaluasi akhir dari model, menunjukkan performa yang sangat baik dengan skor akurasi sebesar 91% dari semua dataset. Presisi model, yang menunjukkan proporsi hasil positif mencapai 92%. Hal ini sejalan dengan *recall* model, yang menunjukkan proporsi semua data positif yang benar-benar teridentifikasi oleh model, yang juga mencapai 97%. Skor F1 ini merupakan gabungan presisi dan *recall*, mencapai 95%

menunjukkan keseimbangan yang baik antara kedua metrik tersebut.

Referensi

- Alfandi Mualo, Fawwaz Ikbar, Elya Juni Arta Sinaga, & Eka Yulia Putri. (2023). Implementasi Algoritma CNN dalam Identifikasi Infeksi Jamur Superfisial. *Jurnal Teknik Mesin, Elektro Dan Ilmu Komputer*, 3(3), 98–107. <https://doi.org/10.55606/teknik.v3i3.2539>
- Azzaroiha, C., Husna, F. N., Rahayu, M., Salsabila, S. N., & Hanifah, U. N. (2022). Keanekaragaman Famili Asteraceae di Pematang Sawah Desa Ubung Kaja, Denpasar Utara, Denpasar. *Biota: Jurnal Ilmiah Ilmu-Ilmu Hayati*, 199–206. <https://doi.org/10.24002/biota.v7i3.5237>
- Bogdan Cretu, & Adrian Iftene. (2021, February 7). Flower-299.
- Diva Tazkya Audya, Elsa Nurpadila, & Ateng Supriyatna. (2023). Inventarisasi dan Identifikasi Keragaman Famili Asteraceae di Kawasan UIN Sunan Gunung Djati Bandung. *Jurnal Riset Rumpun Ilmu Tanaman (JURRIT) Vol.2, No.1 April 2023*.
- Husodo, K., Lubis, C., & Rusdi, Z. (2023). *Klasifikasi tanaman anggrek menggunakan convolutional NEURAL network dengan arsitektur vgg-16*. 8(2).
- Rahmawati, i., & sulistiyowati, T. I. (n.d.). Identifikasi Jenis Tumbuhan dari Famili Asteraceae Di Kawasan Wisata Irenggolo Kediri Identification Of Platns From Asteraceae Family In Irenggolo Kediri Tourism Area. In *Stigma* (Vol. 14). Retrieved from <https://www.eFloras.org>.
- Teknik Elektro, J., & Wegas Intyanto, G. (n.d.). *Klasifikasi Citra Bunga dengan Menggunakan Deep Learning: CNN (Convolution Neural Network)*.