

Penggunaan Teknik *Transfer Learning* pada Metode CNN untuk Pengenalan Tanaman Bunga

Agustina Mufidatuzzainiya ^{(1)*}, Muhammad Faisal ⁽²⁾

Teknik Informatika, UIN Maulana Malik Ibrahim, Malang, Indonesia

e-mail : niyamufida@gmail.com, mfaisal@ti.uin-malang.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 10 Juni 2024, direvisi 6 Oktober 2024, diterima 8 Oktober 2024, dan dipublikasikan 31 Mei 2025.

Abstract

This study explores the impact of using the transfer learning method to improve flower recognition performance using Convolutional Neural Network (CNN) models. The dataset used consists of 4242 flower images divided into five classes: daisy, tulip, rose, sunflower, and dandelion. This research implements three models: basic CNN, VGG16, and EfficientNetB3, to test the effectiveness of transfer learning in flower classification. The basic CNN model achieved a training accuracy of 73.38% and validation accuracy of 71.76%, but it is limited in generalizing to new data. The VGG16 model achieved perfect training accuracy but experienced overfitting, with validation accuracy stabilizing around 85-90%. Meanwhile, the EfficientNetB3 model with transfer learning reached a training accuracy of 98.50% and a validation accuracy of 94.00%, demonstrating strong generalization without significant overfitting. The experiment was conducted using data augmentation techniques, and performance evaluation was carried out using accuracy, precision, and recall metrics. The results show that transfer learning with the EfficientNetB3 model provides the best performance in flower classification compared to the basic CNN and VGG16 models. For future research, further development can be done by expanding the types of flower datasets and applying additional optimization techniques to improve accuracy in more complex models.

Keywords: CNN, Transfer Learning, EfficientNetB3, VGG16, Flower Recognition

Abstrak

Penelitian ini mengeksplorasi pengaruh penggunaan metode *transfer learning* dalam meningkatkan kinerja pengenalan bunga menggunakan model Convolutional Neural Network (CNN). *Dataset* yang digunakan terdiri dari 4.242 gambar bunga yang terbagi dalam lima kelas: *daisy*, tulip, mawar, bunga matahari, dan *dandelion*. Penelitian ini menerapkan tiga model, yaitu CNN dasar, VGG16, dan EfficientNetB3, untuk menguji efektivitas *transfer learning* dalam klasifikasi bunga. Model CNN dasar menunjukkan akurasi pelatihan sebesar 73,38% dan akurasi validasi 71,76%, namun terbatas dalam generalisasi pada data baru. Model VGG16 mencapai akurasi pelatihan sempurna, tetapi mengalami *overfitting* dengan akurasi validasi yang stabil di kisaran 85-90%. Sementara itu, model EfficientNetB3 dengan *transfer learning* mencapai akurasi pelatihan 98,50% dan akurasi validasi 94,00%, menunjukkan kemampuan generalisasi yang kuat tanpa *overfitting* signifikan. Eksperimen dilakukan dengan menggunakan teknik augmentasi data dan evaluasi performa dilakukan menggunakan metrik akurasi, presisi, dan *recall*. Hasil penelitian menunjukkan bahwa *transfer learning* dengan model EfficientNetB3 memberikan performa terbaik dalam klasifikasi bunga, dibandingkan dengan CNN dasar dan VGG16. Untuk penelitian selanjutnya, pengembangan lebih lanjut dapat dilakukan dengan memperluas jenis *dataset* bunga serta menerapkan teknik optimasi tambahan guna meningkatkan akurasi pada model yang lebih kompleks.

Kata Kunci: CNN, Transfer Learning, EfficientNetB3, VGG16, Pengenalan Bunga

1. PENDAHULUAN

Bunga merupakan elemen penting dalam kehidupan sehari-hari yang memiliki nilai budaya, ekonomi, dan ekologis yang signifikan. Dalam ekosistem, bunga berperan sebagai sumber makanan bagi serangga, burung, dan hewan lainnya, serta sebagai bahan obat untuk manusia



Artikel ini didistribusikan mengikuti lisensi Atribusi-NonKomersial CC BY-NC sebagaimana tercantum pada <https://creativecommons.org/licenses/by-nc/4.0/>.

dan hewan (Nugroho, 2015). Selain itu, bunga juga memiliki peran krusial dalam berbagai bidang, seperti pertanian presisi, penelitian botani, pemantauan tanaman, pengobatan Ayurveda, serta pencarian gambar berbasis konten (CBIR) (Arianty et al., 2022). Klasifikasi spesies bunga penting untuk mendukung berbagai aplikasi di bidang tersebut, namun proses ini sering kali menemui tantangan karena perbedaan dalam bentuk, warna, dan struktur bunga yang terkadang sangat mirip.

Meskipun terdapat kemajuan teknologi yang memungkinkan pengenalan bunga secara otomatis menggunakan gambar dibandingkan dengan deskripsi teks, metode identifikasi yang ada masih memiliki tingkat akurasi yang relatif rendah (Nuraini et al., 2023). Hal ini menandakan perlunya solusi yang lebih baik dan akurat untuk mendukung pengenalan bunga secara otomatis. Dalam penelitian klasifikasi bunga, terdapat beberapa tantangan teknis, termasuk kesulitan dalam ekstraksi fitur tradisional serta adanya variasi bentuk dan warna yang mirip antara spesies yang berbeda. Teknologi pembelajaran mendalam, khususnya jaringan saraf konvolusional (CNN), telah terbukti memiliki potensi besar dalam meningkatkan akurasi pengenalan bunga (Saputra et al., 2023). Namun, penggunaan CNN sering kali menghadapi masalah *overfitting* dan optimasi lokal, yang mengurangi efektivitasnya ketika diterapkan pada data validasi yang beragam.

Salah satu metode yang dapat mengatasi keterbatasan CNN adalah *transfer learning*, di mana model yang telah dilatih pada tugas serupa diterapkan untuk memperbaiki kinerja pengenalan pada domain yang berbeda. Dalam konteks pengenalan bunga, *transfer learning* menawarkan potensi untuk meningkatkan akurasi dan generalisasi model terhadap data baru (Falakhi et al., 2022). Penelitian ini bertujuan untuk mengkaji penggunaan metode *transfer learning* dalam meningkatkan kinerja sistem pengenalan bunga, baik dari segi akurasi maupun ketahanan terhadap variasi kondisi lingkungan dan fenotipe tanaman. Dengan menggunakan model yang lebih optimal, diharapkan hasil pengenalan bunga dapat lebih akurat dan *robust* dibandingkan dengan metode yang hanya mengandalkan CNN dasar.

Penelitian sebelumnya, seperti yang dilakukan oleh Narvekar & Rao (2020) menekankan pentingnya CNN dan *transfer learning* dalam klasifikasi bunga dalam konteks pertanian. Sementara itu, Li et al. (2024) mengembangkan metode pengenalan bunga berbasis *Masked Autoencoders*. Berbeda dari penelitian-penelitian tersebut, penelitian ini lebih fokus pada optimalisasi *transfer learning* untuk mengatasi masalah *overfitting* dan optimasi lokal yang umum terjadi dalam model pembelajaran mendalam.


Tujuan penelitian ini adalah mengeksplorasi potensi metode *transfer learning* dalam meningkatkan akurasi dan ketahanan sistem pengenalan bunga. Pendekatan ini diharapkan dapat mengatasi tantangan yang dihadapi oleh penelitian sebelumnya dan memberikan solusi yang lebih baik dalam klasifikasi bunga. Pada akhirnya, penelitian ini bertujuan untuk memberikan kontribusi signifikan dalam pengembangan sistem pengenalan bunga yang lebih akurat dan andal.

2. METODE PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan dengan beberapa tahapan utama yang sistematis dan empiris untuk mencapai hasil yang optimal. Tempat penelitian bersifat fleksibel selama periode Mei hingga Juni 2024. Alat yang digunakan dalam penelitian ini adalah perangkat keras berupa laptop dengan GPU AMD RADEON™ GRAPHICS dan Google Colab untuk membangun dan melatih model CNN.






Gambar 1 Tahapan Penelitian

Tahapan penelitian yang dilakukan adalah sebagai berikut:

- 1) Pengumpulan data: *Dataset* yang digunakan terdiri dari lima jenis bunga (mawar, bunga matahari, aster, *dandelion*, dan tulip). *Dataset* diperoleh dari sumber terbuka dan disesuaikan dengan kebutuhan penelitian.
- 2) *Preprocessing* data: Proses *preprocessing* meliputi *resizing* gambar, normalisasi, dan augmentasi data untuk memperbanyak variasi *dataset* serta mencegah *overfitting*.
- 3) Pembangunan model CNN: Model CNN dibangun menggunakan beberapa lapisan, termasuk lapisan konvolusi, *pooling*, dan *fully connected*, serta menggunakan teknik *transfer learning* dari model InceptionV3 yang telah dilatih sebelumnya.
- 4) Pelatihan model: Model dilatih menggunakan *dataset* yang telah diproses, dan teknik *transfer learning* diterapkan untuk mempercepat proses pelatihan.
- 5) Evaluasi model: Evaluasi dilakukan dengan menghitung metrik akurasi, presisi, dan *recall*.

2.2 Dataset



Gambar 2 Contoh Gambar pada Dataset Flower Recognition



Flower Recognition, *dataset* tersebut dibuat oleh Alexander Mamaev pada tahun 2021 (<https://www.kaggle.com/datasets/alxmamaev/flowers-recognition>). *Dataset* ini berisi 4242 gambar bunga. Pengumpulan data didasarkan pada data dari Flickr, Google Images, dan Yandex Images. Gambar-gambar tersebut dibagi menjadi lima kelas: *daisy*, tulip, mawar, bunga matahari, dan *dandelion*. Untuk setiap kelas terdapat sekitar 800 foto. Foto-foto tersebut tidak beresolusi tinggi, resolusinya sekitar 320x240 piksel. Foto-foto ini tidak dikurangi menjadi satu ukuran tunggal, mereka memiliki proporsi yang berbeda-beda. Contoh gambar yang ada pada *dataset* Flower Recognition bisa dilihat di Gambar 2.

2.3 Convolutional Neural Network

Convolutional Neural Networks (CNN) adalah algoritma pembelajaran mendalam yang khusus dirancang untuk menganalisis data visual, efektif dalam tugas-tugas seperti klasifikasi gambar, pengenalan objek, dan deteksi objek. Struktur CNN terdiri dari beberapa lapisan utama, yaitu lapisan konvolusi (Fuadah et al., 2022) untuk mengekstraksi fitur dari gambar, lapisan aktivasi untuk memperkenalkan non-linearitas, lapisan *pooling* untuk mengurangi dimensi peta fitur sambil menjaga informasi penting, dan lapisan *fully connected* untuk klasifikasi akhir. CNN bekerja dengan mengekstraksi fitur dasar seperti tepi dan tekstur pada lapisan awal (Danial & Setiawati, 2024), lalu mengenali fitur yang lebih kompleks pada lapisan berikutnya, dan akhirnya menggunakan fitur-fitur ini untuk membuat keputusan klasifikasi.

Keunggulan CNN meliputi otomatisasi ekstraksi fitur (Ibrahim et al., 2022), ketahanan terhadap variasi kondisi seperti pencahayaan dan orientasi, kemampuan menangani data besar dan kompleks, serta kemampuan menangkap ketergantungan spasial dalam gambar. CNN diterapkan dalam berbagai bidang seperti penglihatan komputer, otomatisasi kendaraan, kesehatan, keamanan, dan pertanian presisi, menjadikannya teknologi utama untuk analisis gambar dan video. Convolutional Neural Network (CNN) menggunakan beberapa operasi matematika dasar dalam arsitekturnya (Darmanto, 2019). Berikut adalah rumus-rumus utama yang digunakan dalam model CNN.

2.3.1 Convolution

Operasi konvolusi melibatkan filter (kernel) K yang berukuran $m \times n$ yang diterapkan pada gambar input I . Hasil konvolusi pada posisi (x, y) dihitung sebagai jumlah dari hasil kali elemen-elemen filter dan elemen-elemen gambar yang bersesuaian. Persamaan perhitungan konvolusi dijabarkan pada Pers. (1).

$$(I \cdot K)(x, y) = \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} I(x+i, y+j) \cdot K(i, j) \quad (1)$$

2.3.2 ReLU

Fungsi aktivasi ReLU menggantikan semua nilai negatif dalam peta fitur dengan nol, memperkenalkan non-linearitas ke dalam model dan membantu dalam mengatasi masalah *vanishing gradient*. Persamaan perhitungan fungsi aktivasi ReLU dijabarkan pada Pers. (2).

$$f(x) = \max(0, x) \quad (2)$$

2.3.3 Pooling

Max pooling mengurangi dimensi peta fitur dengan mengambil nilai maksimum dari setiap area kecil $m \times n$ dalam peta fitur, menjaga fitur-fitur penting sambil mengurangi jumlah parameter dan komputasi. Persamaan perhitungan *pooling* dijabarkan pada Pers. (3).

$$P_{max}(x, y) = \max_{0 \leq i < m, 0 \leq j < n} I(x+i, y+j) \quad (3)$$




2.3.4 Fully Connected Layer

Di lapisan *fully connected*, setiap neuron dihubungkan dengan semua neuron di lapisan sebelumnya. W adalah matriks bobot, x adalah input, b adalah bias, dan f adalah fungsi aktivasi. Lapisan ini menggabungkan fitur-fitur yang telah diekstraksi untuk membuat prediksi klasifikasi akhir. Persamaan perhitungan *fully connected layer* dijabarkan pada Pers. (4).

$$y = f(W \cdot x + b) \quad (4)$$

2.4 Transfer Learning

Transfer learning adalah teknik dalam pembelajaran mendalam yang memanfaatkan model yang telah dilatih sebelumnya (Harahap et al., 2022) pada satu tugas untuk meningkatkan kinerja pada tugas baru yang terkait. Dengan menggunakan pengetahuan yang sudah diperoleh dari model yang dilatih pada *dataset* yang sangat besar, *transfer learning* memungkinkan proses pelatihan menjadi lebih cepat dan efisien. Model yang telah dilatih sebelumnya ini mempunyai sebuah pemahaman yang kuat mengenai konsep dasar yang ada, sehingga ketika diterapkan pada tugas baru, meskipun dengan *dataset* yang lebih terbatas, hasil yang dicapai dapat lebih baik. Selain itu, *transfer learning* mengurangi kebutuhan akan sumber daya komputasi yang besar (Widyaya & Budi, 2021), karena model tidak perlu dilatih dari awal. Ini membuat *transfer learning* menjadi alat yang sangat berharga dalam pengembangan model pembelajaran mesin, mempercepat proses pengembangan dan meningkatkan kinerja dalam berbagai aplikasi.



Gambar 3 Pengembangan *Transfer learning* pada CNN (Drenyovszki, 2024)

Berdasarkan Gambar 3 tersebut, *transfer learning* merupakan sebuah metode dalam *machine learning* di mana pengetahuan yang telah diperoleh dari satu model (*source model*) pada suatu tugas dengan *dataset* yang besar (*source data*) dapat digunakan untuk meningkatkan performa model pada tugas yang berbeda namun terkait, yang memiliki *dataset* lebih kecil (*target data*). Dalam ilustrasi, "*source model*" dilatih menggunakan data yang besar seperti *ImageNet*, yang memiliki banyak label (*source labels*). Setelah pengetahuan dipelajari oleh model ini, pengetahuan tersebut ditransfer ke "*target model*" yang ditujukan untuk tugas yang berbeda, menggunakan *dataset* yang lebih kecil seperti PASCAL, yang memiliki lebih sedikit label (*target labels*). Transfer ini memungkinkan target model untuk memanfaatkan pengetahuan yang diperoleh dari *source model*, sehingga dapat mencapai performa yang lebih baik meskipun data yang tersedia terbatas.

2.5 Evaluasi Kinerja Model

Untuk mengevaluasi kinerja model, digunakan beberapa metrik evaluasi yang meliputi akurasi, presisi, dan *recall*. Akurasi mengukur proporsi prediksi yang benar dari keseluruhan prediksi yang dibuat oleh model, dengan rumus dituliskan pada Pers. (5). Presisi mengukur seberapa akurat prediksi positif model, dengan rumus pada Pers. (6). *Recall*, atau sensitivitas, mengukur seberapa baik model dalam mengidentifikasi semua kasus positif, dengan rumus pada Pers. (7). Di mana TP (*True Positive*) menunjukkan jumlah kasus positif yang diprediksi benar, TN (*True*



Negative) adalah jumlah kasus negatif yang diprediksi benar, *FP (False Positive)* merupakan jumlah kasus negatif yang diprediksi salah sebagai positif, dan *FN (False Negative)* menunjukkan jumlah kasus positif yang diprediksi salah sebagai negatif.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$Presisi = \frac{TP}{TP + FP} \quad (6)$$


$$Recall = \frac{TP}{TP + FN} \quad (7)$$

3. HASIL DAN PEMBAHASAN

3.1 Arsitektur Model CNN yang Diusulkan

Arsitektur model Convolutional Neural Network (CNN) dimulai dengan lapisan input (Alwanda et al., 2020), tempat gambar masukan dimasukkan ke dalam model. Gambar ini kemudian diproses melalui *Convolutional Layer 1* yang menggunakan filter untuk mengekstraksi fitur-fitur dasar seperti tepi dan tekstur, dengan aktivasi ReLU untuk memperkenalkan non-linearitas. Selanjutnya, *Pooling Layer 1* mengurangi dimensi peta fitur yang dihasilkan untuk mempertahankan fitur penting sambil mengurangi jumlah parameter dan komputasi.

Proses ini diulang dengan *Convolutional Layer 2* untuk mengekstraksi fitur yang lebih kompleks dan *Pooling Layer 2* untuk mengurangi dimensi lebih lanjut. Setelah fitur-fitur diekstraksi, lapisan *fully connected* menghubungkan semua neuron dari lapisan sebelumnya untuk menggabungkan fitur-fitur tersebut dan membuat keputusan klasifikasi akhir. Lapisan *output* kemudian menghasilkan prediksi akhir dari model, seperti mengklasifikasikan jenis bunga dalam gambar (Tama & Santi, 2023). Garis-garis panah yang menghubungkan setiap lapisan menunjukkan aliran data dan proses transformasi yang terjadi, menggambarkan bagaimana CNN memproses dan menganalisis data visual untuk menghasilkan prediksi yang akurat. Gambaran untuk arsitektur model CNN bisa dilihat di Gambar 4.



Gambar 4 Arsitektur Model CNN


Hasil pelatihan dan evaluasi model *Convolutional Neural Network* (CNN) selama 20 *epoch* dapat dilihat di Tabel 1. Pada setiap *epoch*, model CNN mengalami peningkatan kinerja dalam hal akurasi dan penurunan nilai *loss*. Awalnya, pada *epoch* pertama, akurasi model hanya sekitar 24,31% dengan nilai *loss* sebesar 2,0919. Namun, seiring berjalannya pelatihan, akurasi model secara bertahap meningkat, mencapai puncaknya pada *epoch* ke-20 dengan akurasi sebesar 73,38%. Selama proses pelatihan, nilai *loss* model juga terus menurun dari 2,0919 pada *epoch* pertama menjadi 0,7730 pada *epoch* ke-20. Hasil validasi juga menunjukkan tren yang serupa, di mana akurasi pada data validasi meningkat dari 22,22% pada awal pelatihan menjadi 71,76% pada akhirnya, sementara nilai *loss* pada data validasi mengalami penurunan dari 1,9976 menjadi 0,7509. Hal ini menunjukkan bahwa model CNN berhasil belajar dari data pelatihan dan menggeneralisasi dengan baik data yang belum pernah dilihat sebelumnya.



Dari Tabel 1 dapat ditampilkan grafiknya sebagaimana gambar grafik pada Gambar 5 di bawah. Gambar tersebut merupakan gambar dua grafik yang menggambarkan kinerja model pembelajaran mesin selama proses pelatihan. Grafik kiri menunjukkan hubungan antara *loss* (fungsi kerugian) dan jumlah *epoch* (iterasi). Garis merah mewakili nilai *loss* pada data pelatihan, sedangkan garis hijau mewakili nilai *loss* pada data validasi. Kedua kurva ini menurun seiring bertambahnya *epoch*, menunjukkan bahwa model semakin baik dalam memprediksi target baik pada data pelatihan maupun data validasi. Pada akhir pelatihan, nilai *loss* pada data pelatihan dan validasi hampir mendekati, menunjukkan bahwa tidak ada *overfitting* yang signifikan.

Tabel 1 Hasil Performa Model CNN

<i>epoch</i>	<i>accuracy</i>	<i>loss</i>	<i>val_accuracy</i>	<i>val_loss</i>
1	0,2431	2,0919	0,2222	1,9976
2	0,2825	1,7935	0,2222	2,0664
3	0,3179	1,6505	0,3449	1,5945
4	0,3837	1,4683	0,4792	1,2356
5	0,4467	1,3376	0,4653	1,2172
6	0,4632	1,3208	0,5463	1,0841
7	0,5076	1,2043	0,5602	1,0479
8	0,5276	1,1701	0,5856	1,0015
9	0,5410	1,1131	0,5486	1,0631
10	0,5737	1,0488	0,5972	0,9776
11	0,5839	1,0548	0,6065	0,9733
12	0,5953	1,0230	0,5694	1,0422
13	0,6163	0,9814	0,5602	1,1040
14	0,6237	0,9801	0,5926	1,0150
15	0,6639	0,8849	0,6227	0,9695
16	0,6506	0,9282	0,6343	0,9646
17	0,6828	0,8455	0,6481	0,9019
18	0,7048	0,8243	0,6736	0,8803
19	0,7101	0,8111	0,6505	0,9748
20	0,7338	0,7730	0,7176	0,7509



Gambar 5 Grafik Nilai Loss dan Nilai Accuracy

Adapun grafik kanan menunjukkan hubungan antara akurasi dan jumlah *epoch*. Garis merah mewakili akurasi pada data pelatihan, sementara garis hijau mewakili akurasi pada data validasi. Kedua kurva ini meningkat seiring bertambahnya *epoch*, menandakan bahwa model semakin akurat dalam melakukan prediksi. Meskipun kurva akurasi pada data validasi sedikit fluktuatif, tren keseluruhan menunjukkan peningkatan yang konsisten. Kesimpulannya, model yang dilatih menunjukkan peningkatan kinerja yang stabil, ditunjukkan oleh penurunan *loss* dan peningkatan akurasi pada kedua data pelatihan dan validasi, tanpa indikasi *overfitting* yang jelas.




3.2 Eksperimen Berbasis *Transfer learning*

Sebelum memulai langkah-langkah eksperimen, pendekatan berbasis *transfer learning* digunakan sebagai metode utama dalam penelitian ini. *Transfer learning* memungkinkan pemanfaatan model pra-terlatih yang telah dikembangkan sebelumnya untuk menyelesaikan tugas klasifikasi gambar pada *dataset* yang berbeda, dalam hal ini, klasifikasi jenis bunga. Dengan menggunakan model pra-terlatih seperti CNN dan EfficientNet, model ini dapat memanfaatkan pengetahuan yang diperoleh dari *dataset* besar, seperti ImageNet, dan menerapkannya pada tugas spesifik pengenalan bunga. Pendekatan ini tidak hanya mempercepat proses pelatihan, tetapi juga meningkatkan akurasi dan mengurangi kemungkinan *overfitting* pada *dataset* bunga yang terbatas.

Setelah menemukan model yang tepat, eksperimen dimulai dengan mengumpulkan data gambar bunga yang terdiri dari lima jenis bunga: mawar (*rose*), bunga matahari (*sunflower*), aster (*daisy*), *dandelion*, dan tulip. Data ini dipecah menjadi data latih, validasi, dan uji dengan rasio masing-masing 80%, 10%, dan 10%. Data augmentasi dilakukan pada data latih untuk meningkatkan variasi gambar dengan berbagai transformasi seperti rotasi, pergeseran, *zoom*, dan *flip* horizontal.

Transfer learning dengan EfficientNetB3 adalah model yang telah dilatih sebelumnya pada *dataset* ImageNet. Dalam eksperimen ini, arsitektur dasar EfficientNetB3 digunakan sebagai *feature extractor*, dan beberapa lapisan tambahan ditambahkan pada bagian atasnya untuk menyesuaikan model dengan tugas klasifikasi bunga. Lapisan tambahan termasuk GlobalAveragePooling2D, *batch normalization*, blok *dens*, dan lapisan *output* dengan aktivasi *softmax*. Model ini kemudian dilatih menggunakan *optimizer* Adamax dengan *learning rate* yang lebih rendah.

Transfer learning dengan VGG16 adalah model lain yang telah dilatih sebelumnya pada *dataset* ImageNet. Sama seperti pada EfficientNetB3, arsitektur dasar VGG16 digunakan sebagai *feature extractor*, dengan beberapa lapisan tambahan yang ditambahkan pada bagian atasnya. Lapisan tambahan ini termasuk GlobalAveragePooling2D, *batch normalization*, blok *dens*, dan lapisan *output* dengan aktivasi *softmax*. Model ini juga dilatih menggunakan *optimizer* Adamax dengan *learning rate* yang lebih rendah.



Gambar 6 Grafik Nilai *Loss* dan *Accuracy* EfficientNetB3


Gambar 6 menunjukkan hasil pelatihan dan evaluasi model menggunakan EfficientNetB3 dengan dua metrik utama: nilai *loss* dan nilai akurasi. Grafik di sebelah kiri menggambarkan nilai *loss*, yaitu ukuran kesalahan prediksi model, di mana nilai yang lebih rendah menunjukkan kinerja model yang lebih baik. Sumbu Y menunjukkan nilai *loss*, sedangkan sumbu X menunjukkan jumlah *epoch* atau iterasi pelatihan. Garis merah mewakili nilai *loss* pada data pelatihan, dan garis hijau menunjukkan nilai *loss* pada data validasi. Dari grafik ini, kita dapat melihat bahwa



nilai *loss* pada kedua *dataset* ini menunjukkan tren penurunan seiring bertambahnya jumlah *epoch*. Pada awal pelatihan, nilai *loss* cukup tinggi, tetapi seiring waktu, nilai *loss* menurun secara konsisten. Hal ini menunjukkan bahwa model semakin baik dalam memprediksi, dan kesalahan prediksi berkurang. Pada akhir pelatihan, nilai *loss* pada data pelatihan dan validasi hampir mendekati, menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan dan dapat menggeneralisasi dengan baik data yang sebelumnya tidak terlihat.

Grafik di sebelah kanan menunjukkan skor akurasi, yang mewakili persentase prediksi yang benar untuk keseluruhan model. Sumbu Y menunjukkan nilai presisi dan sumbu X menunjukkan jumlah *epoch*. Garis merah mewakili nilai akurasi data latih, dan garis hijau mewakili nilai akurasi data validasi. Grafik ini menunjukkan bahwa nilai akurasi untuk kedua *dataset* meningkat seiring dengan bertambahnya jumlah *epoch*. Pada awal pelatihan, nilai akurasinya relatif rendah, namun seiring berjalannya waktu nilai akurasinya meningkat secara signifikan. Hal ini menunjukkan bahwa akurasi prediksi model menjadi semakin akurat. Di akhir pelatihan, nilai akurasi data pelatihan dan validasi mendekati nilai tinggi, yang menunjukkan bahwa model cukup belajar dari data pelatihan untuk membuat prediksi akurat pada data validasi.

Secara keseluruhan, kedua grafik tersebut menunjukkan bahwa model EfficientNetB3 berhasil dalam pelatihan dan evaluasi. Penurunan nilai *loss* dan peningkatan nilai akurasi yang konsisten menunjukkan bahwa model dapat mempelajari pola dari data dengan baik. Tidak adanya indikasi *overfitting* yang signifikan, di mana nilai *loss* dan akurasi pada data validasi tetap sejalan dengan data pelatihan, Hal ini menunjukkan bahwa model mempunyai kemampuan generalisasi yang baik. Artinya, model tersebut berkinerja baik tidak hanya pada data pelatihan, tetapi juga pada data baru yang belum pernah ada sebelumnya.




Gambar 7 Confusion Matrix EfficientNetB3

Gambar 7 merupakan *confusion matrix* yang menggambarkan kinerja model EfficientNetB3 dalam mengklasifikasikan lima jenis bunga: aster, dandelion, mawar, bunga matahari, dan tulip. Matriks ini menunjukkan jumlah prediksi yang benar untuk setiap kelas. Diagonal utama menunjukkan jumlah prediksi benar untuk setiap kelas, sementara sel-sel lainnya menunjukkan kesalahan klasifikasi. Misalnya, model memprediksi 75 dari 82 bunga *daisy* dengan benar, tetapi salah mengklasifikasikan beberapa sebagai *dandelion*, *rose*, *sunflower*, atau tulip. *Dandelion* memiliki akurasi tertinggi dengan 100 prediksi benar dari 104, menunjukkan bahwa model sangat baik dalam mengenali *dandelion*. Kesalahan klasifikasi relatif kecil untuk semua jenis bunga,




menunjukkan bahwa model EfficientNetB3 bekerja cukup baik dalam membedakan antara berbagai jenis bunga dengan tingkat akurasi yang tinggi.

Adapun Gambar 8 merupakan grafik yang menunjukkan nilai *loss* dan akurasi selama pelatihan dan validasi menggunakan model VGG16. Grafik di sebelah kiri menggambarkan perubahan nilai *loss*, di mana *loss* pelatihan (garis merah) secara konsisten menurun seiring bertambahnya *epoch*, menunjukkan bahwa model belajar dengan baik pada data pelatihan. Namun, *loss* validasi (garis hijau) mulai meningkat setelah sekitar 10 *epoch*, yang mengindikasikan adanya *overfitting*. Grafik di sebelah kanan menunjukkan perubahan akurasi, di mana akurasi pelatihan (garis merah) meningkat tajam dan mencapai hampir 100%, sementara akurasi validasi (garis hijau) stabil di sekitar 85-90% dan mengalami sedikit fluktuasi, mencerminkan kinerja model yang stabil namun menunjukkan tanda-tanda *overfitting*. Secara keseluruhan, model VGG16 menunjukkan kinerja yang baik pada data pelatihan tetapi mungkin mengalami *overfitting* pada data validasi.



Gambar 8 Grafik Nilai Loss dan Accuracy VGG16



Gambar 9 Confusion Matrix VGG16

Selanjutnya terdapat Gambar 9 yang merupakan *confusion matrix* vgg16, *confusion matrix* tersebut menunjukkan kinerja model VGG16 dalam mengklasifikasikan lima jenis bunga: aster, *dandelion*, mawar, bunga matahari, dan tulip. Model berhasil mengklasifikasikan sebagian besar gambar dengan benar, terutama untuk kelas *dandelion* dan tulip. Namun, terdapat beberapa kesalahan klasifikasi, terutama antara *rose* dan tulip, di mana gambar *rose* sering salah



diklasifikasikan sebagai tulip. Meski begitu, hasil ini dapat memperlihatkan bahwasannya model memiliki akurasi yang cukup baik, tetapi masih memerlukan perbaikan untuk meningkatkan ketepatan dalam membedakan beberapa kelas bunga yang mirip secara visual. Informasi dari *confusion matrix* ini dapat digunakan untuk mengoptimalkan model lebih lanjut.

Tabel 2 Ringkasan Hasil (Result Summary)

Model	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss	Comments
CNN	73,38%	71,76%	0,7730	0,7509	Model dasar CNN menunjukkan peningkatan kinerja yang stabil tanpa <i>overfitting</i> signifikan.
EfficientNetB3	98,50%	94,00%	0,050	0,300	<i>Model transfer learning</i> dengan EfficientNetB3 memberikan hasil yang sangat baik dan memiliki kemampuan generalisasi yang kuat.
VGG16	100%	85-90%	0,020	0,450	VGG16 menunjukkan performa tinggi pada data pelatihan tetapi mengalami <i>overfitting</i> pada data validasi.

4. KESIMPULAN

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan performa model CNN, VGG16, dan EfficientNetB3 dalam klasifikasi bunga menggunakan *dataset* yang terbatas. Model CNN dasar yang dibangun dari awal menunjukkan akurasi 73,38% pada data pelatihan dan 71,76% pada data validasi. Meskipun model ini mampu belajar dengan baik dan menunjukkan penurunan *loss* yang konsisten selama pelatihan, hasil ini menunjukkan bahwa kinerja model dasar masih terbatas dalam menangani data baru secara optimal.

Model *transfer learning* dengan EfficientNetB3 berhasil menunjukkan performa yang sangat baik dengan akurasi pelatihan 98,50% dan akurasi validasi 94,00%. Dengan nilai *loss* yang rendah pada kedua *dataset*, model ini berhasil meminimalkan *overfitting* dan memiliki kemampuan generalisasi yang kuat. Model ini terbukti unggul dalam klasifikasi bunga dibandingkan dengan model lainnya. Sebaliknya, model VGG16 mengalami masalah *overfitting* meskipun menunjukkan akurasi tinggi pada data pelatihan. Akurasi stabil di kisaran 85-90% pada data validasi dan nilai *loss* meningkat setelah beberapa *epoch*, menunjukkan keterbatasan model dalam menggeneralisasi data baru, yang mengurangi efektivitasnya dibandingkan EfficientNetB3.

Berdasarkan hasil penelitian ini, dapat disimpulkan bahwa model *transfer learning* dengan EfficientNetB3 memberikan performa terbaik dalam klasifikasi bunga dengan *dataset* terbatas, menjadikannya pilihan yang lebih tepat dibandingkan dengan model CNN dasar dan VGG16. Penelitian ini menunjukkan bahwa penggunaan model pra-terlatih tidak hanya mempercepat proses pelatihan, tetapi juga menghasilkan kinerja yang lebih konsisten dan akurat pada data validasi, sehingga dapat menjadi solusi efektif dalam tugas klasifikasi gambar dengan jumlah data yang terbatas.

DAFTAR PUSTAKA

Alwanda, M. R., Ramadhan, R. P. K., & Alamsyah, D. (2020). Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle. *Jurnal Algoritme*, 1(1), 45–56. <https://doi.org/10.35957/algoritme.v1i1.434>



Artikel ini didistribusikan mengikuti lisensi Atribusi-NonKomersial CC BY-NC sebagaimana tercantum pada <https://creativecommons.org/licenses/by-nc/4.0/>.

- Arianty, R., Maukar, M., & Lestari, O. B. (2022). Pengukuran Kemiripan Fitur pada Sistem Temu Kembali Citra Berbasis Konten Menggunakan Euclidian Distance. *Jurnal Ilmiah Informatika Komputer*, 27(1), 1–18. <https://doi.org/10.35760/ik.2022.v27i1.6095>
- Danial, N. H., & Setiawati, D. (2024). Convolutional Neural Network (CNN) Based on Artificial Intelligence in Periodontal Diseases Diagnosis. *Interdental Jurnal Kedokteran Gigi (IJKG)*, 20(1), 139–148. <https://doi.org/10.46862/interdental.v20i1.8641>
- Darmanto, H. (2019). Pengenalan Spesies Ikan Berdasarkan Kontur Otolith Menggunakan Convolutional Neural Network. *Joined Journal (Journal of Informatics Education)*, 2(1), 41. <https://doi.org/10.31331/joined.v2i1.847>
- Drenyovszki, R. (2024). Solving a Classification Problem Using Transfer Learning on Small Image Datasets. *Gradus*, 11(1). <https://doi.org/10.47833/2024.1.CSC.011>
- Falaxhi, B., Achmal, E. F., Rizaldi, M., Athallah, R. R. R., & Yudistira, N. (2022). Perbandingan Model AlexNet dan ResNet dalam Klasifikasi Citra Bunga Memanfaatkan Transfer Learning. *Jurnal Ilmu Komputer dan Agri-Informatika*, 9(1), 70–78. <https://doi.org/10.29244/jika.9.1.70-78>
- Fuadah, Y. N., Ubaidullah, I. D., Ibrahim, N., Taliningsing, F. F., Sy, N. K., & Pramuditho, M. A. (2022). Optimasi Convolutional Neural Network dan K-Fold Cross Validation pada Sistem Klasifikasi Glaukoma. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(3), 728. <https://doi.org/10.26760/elkomika.v10i3.728>
- Harahap, M., Laia, E. M., Sitanggang, L. S., Sinaga, M., Sihombing, D. F., & Husein, A. M. (2022). Deteksi Penyakit Covid-19 pada Citra X-Ray dengan Pendekatan Convolutional Neural Network (CNN). *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(1), 70–77. <https://doi.org/10.29207/resti.v6i1.3373>
- Ibrahim, N., Lestary, G. A., Hanafi, F. S., Saleh, K., Pratiwi, N. K. C., Haq, M. S., & Mastur, A. I. (2022). Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(1), 162. <https://doi.org/10.26760/elkomika.v10i1.162>
- Li, Y., Lv, Y., Ding, Y., Zhu, H., Gao, H., & Zheng, L. (2024). Research on a Flower Recognition Method Based on Masked Autoencoders. *Horticulturae*, 10(5), 517. <https://doi.org/10.3390/horticulturae10050517>
- Narvekar, C., & Rao, M. (2020). Flower Classification Using CNN and Transfer Learning in CNN-Agriculture Perspective. *2020 3rd International Conference on Intelligent Sustainable Systems (ICISS)*, 660–664. <https://doi.org/10.1109/ICISS49785.2020.9316030>
- Nugroho, A. S. (2015). Analisis Keanekaragaman Jenis Tumbuhan Berbuah di Hutan Lindung Surokonto, Kendal, Jawa Tengah dan Potensinya Sebagai Kawasan Konservasi Burung. *Prosiding Seminar Nasional Masyarakat Biodiversitas Indonesia*. <https://doi.org/10.13057/psnmbi/m010316>
- Nuraini, R., Destriana, R., Nurnaningsih, D., Daniarti, Y., & Alexander, A. D. (2023). Sunflower Image Classification Using Multiclass Support Vector Machine Based on Histogram Characteristics. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(1), 146–152. <https://doi.org/10.29207/resti.v7i1.4673>
- Saputra, T., Nurmaini, S., Roseno, M. T., & Syaputra, H. (2023). Heart Chamber Segmentation in Cardiomegaly Conditions Using the CNN Method with U-Net Architecture. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 12(3), 455–461. <https://doi.org/10.32736/sisfokom.v12i3.1976>
- Tama, A. M., & Santi, R. C. N. (2023). Klasifikasi Jenis Tanaman Hias Menggunakan Metode Convolutional Neural Network (CNN). *INTECOMS: Journal of Information Technology and Computer Science*, 6(2), 764–770. <https://doi.org/10.31539/intecom.v6i2.7002>
- Widyaya, J. E., & Budi, S. (2021). Pengaruh Preprocessing Terhadap Klasifikasi Diabetic Retinopathy dengan Pendekatan Transfer Learning Convolutional Neural Network. *Jurnal Teknik Informatika dan Sistem Informasi*, 7(1). <https://doi.org/10.28932/jutisi.v7i1.3327>

