

Klasifikasi Citra Spesies Bunga di Indonesia Berbasis *Convolutional Neural Network* Menggunakan Teknik *Transfer Learning*

Arif Rahman^{1*}, Mansyur Salim², Imam Riadi³

^{1,2,3}Sistem Informasi, Fakultas Sains dan Teknologi Terapan, Universitas Ahmad Dahlan Yogyakarta

^{1*}arif.rahman@is.uad.ac.id, ²salim1700016093@webmail.uad.ac.id, ³imam.riadi@is.uad.ac.id

ABSTRACT

Indonesia has around 20,000 species of flowers with a wide variety of shapes, colors, and structures, making manual flower classification a challenge, primarily due to the similarity of colors between species. This study aims to develop a flower classification model using a Convolutional Neural Network (CNN) based on MobileNetV2, with transfer learning as the primary method. The dataset was sourced from the 2015 Superior Floriculture Variety Catalog by the Agricultural Research and Development Agency, consisting of 11 types of flowers with a total of 2,137 images divided into training, validation, and testing data. The CNN model without transfer learning achieved an accuracy of 42% on the test data, while the application of transfer learning improved accuracy to 73%. The results show that the transfer learning method, mainly using MobileNetV2 with ImageNet weights, significantly improves accuracy by 52% compared to the method without transfer learning. This study demonstrates that a transfer learning-based model can be implemented to efficiently and optimally classify flower images, with potential application on smartphone devices.

Keywords: Flower, CNN, Classification, Transfer Learning.

ABSTRAK

Indonesia memiliki sekitar 20.000 spesies bunga dengan berbagai bentuk, warna, dan struktur, yang menjadikan klasifikasi manual bunga menjadi tantangan, terutama karena kemiripan warna antarspesies. Penelitian ini bertujuan mengembangkan model klasifikasi bunga menggunakan *Convolutional Neural Network* (CNN) berbasis MobileNetV2 dengan teknik *transfer learning*. Dataset diambil dari Katalog Varietas Unggul Florikultura tahun 2015 oleh Badan Penelitian dan Pengembangan Pertanian, mencakup 11 jenis bunga dengan total 2137 citra, yang dibagi menjadi data latih, validasi, dan uji. Model CNN tanpa *transfer learning* menghasilkan akurasi 42% pada data uji, sedangkan penerapan *transfer learning* meningkatkan akurasi menjadi 73%. Hasil penelitian menunjukkan bahwa teknik *transfer learning*, khususnya dengan MobileNetV2 menggunakan bobot ImageNet, memberikan peningkatan akurasi yang signifikan, yakni 52% lebih baik dibandingkan metode tanpa *transfer learning*. Penelitian ini membuktikan bahwa model berbasis *transfer learning* dapat diimplementasikan untuk klasifikasi citra bunga secara efisien dan optimal, serta dapat digunakan pada perangkat berbasis *smartphone*.

Kata Kunci: Bunga, CNN, Klasifikasi, *Transfer Learning*.

1. PENDAHULUAN

Indonesia merupakan negara dengan keanekaragaman hayati yang sangat tinggi, terutama dalam hal flora. Berbagai spesies bunga yang tumbuh di Indonesia tidak hanya memiliki nilai estetika, tetapi juga berperan penting dalam menjaga ekosistem dan budaya lokal. Dengan lebih dari 30.000 spesies bunga, potensi untuk penelitian dalam bidang florikultura sangat besar [1]. Namun, identifikasi spesies bunga masih sering dilakukan secara manual, yang memerlukan keahlian khusus serta waktu yang relatif lama.

Perkembangan teknologi dalam pengolahan citra dan pembelajaran mesin, khususnya Convolutional Neural Networks (CNN), telah memberikan peluang baru untuk klasifikasi spesies bunga secara otomatis. CNN terbukti efektif dalam berbagai aplikasi pengenalan pola dan klasifikasi citra, termasuk dalam pengenalan objek dan klasifikasi spesies tumbuhan [2]. Salah satu pendekatan yang menjanjikan dalam konteks ini adalah *transfer learning*, yang memungkinkan pemanfaatan model yang telah dilatih pada dataset besar untuk meningkatkan performa pada dataset yang lebih kecil, seperti yang sering ditemukan dalam penelitian spesies flora [3].

Sejumlah penelitian telah dilakukan untuk mengidentifikasi spesies bunga menggunakan pembelajaran mesin dan pengolahan citra. Studi dalam [4] membahas penggunaan CNN untuk klasifikasi gambar bunga menggunakan database berisi 9500 gambar. Pelatihan dilakukan dalam lima tahap menggunakan berbagai arsitektur CNN untuk mencari konfigurasi terbaik. Penelitian ini berhasil mencapai tingkat akurasi 97,78%, lebih tinggi dibandingkan model klasifikasi lainnya yang menggunakan dataset serupa. Penelitian [5] membandingkan dua algoritma yaitu CNN dan Support Vector Machine (SVM). CNN, yang merupakan algoritma *deep learning*, menunjukkan hasil yang lebih baik dibandingkan SVM. Hasil ini menunjukkan bahwa CNN lebih unggul dalam menangkap pola dan fitur kompleks dari gambar bunga. Klasifikasi bunga menggunakan model CNN berbasis ResNet dilakukan dalam [6] melibatkan dataset lebih dari 3000 gambar dari lima jenis bunga. Model yang telah dilatih berhasil meningkatkan akurasi klasifikasi dengan mencapai akurasi rata-rata 91% pada data uji. Penelitian [7] mengembangkan model CNN untuk klasifikasi delapan jenis bunga lokal menggunakan 5120 gambar pelatihan dan 1280 gambar pengujian. Implementasi delapan metode augmentasi data untuk meningkatkan volume dataset dalam model ini mencapai akurasi klasifikasi sebesar 85%.

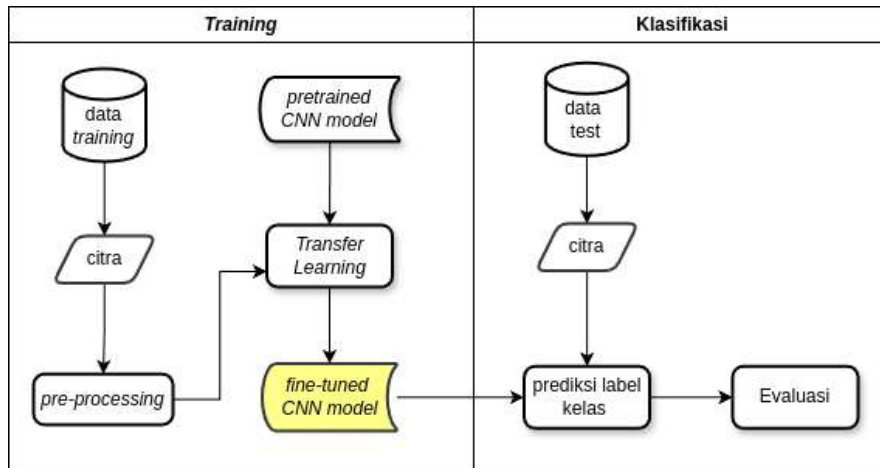
Penelitian [8] melakukan klasifikasi spesies tanaman menggunakan CNN dan *transfer learning*. Hasilnya menunjukkan bahwa penggunaan CNN yang telah dilatih (*pre-trained*) dapat mempercepat proses pelatihan dan meningkatkan akurasi klasifikasi secara signifikan. Klasifikasi bunga berbasis CNN dengan *transfer learning* diusulkan dalam [9]. Model VGG19 digunakan untuk ekstraksi fitur, dan untuk mengklasifikasi bunga. Hasil penelitian berhasil mengklasifikasi bunga dengan akurasi 91,1%. Studi dalam [10] membahas klasifikasi lima jenis bunga: *daisy*, *dandelion*, *rose*, *sunflower*, dan tulip. Proses klasifikasi menggunakan metode *transfer learning* dengan arsitektur DenseNet dan NasNetLarge. Hasil pengujian menunjukkan arsitektur DenseNet mencapai akurasi pengujian 89%, sedangkan NasNetLarge memperoleh akurasi 86%. Klasifikasi bunga jenis mawar menggunakan CNN yang dilatih dengan citra berwarna RGB dilakukan pada penelitian [11]. Hasil penelitian menunjukkan akurasi klasifikasi mencapai 96,33%, yang dapat meningkatkan efisiensi identifikasi jenis bunga bagi pengguna.

Penelitian-penelitian yang telah dilakukan sebagaimana telah dijelaskan di atas, sebagian besar berfokus pada dataset internasional atau bunga non-lokal, sehingga kurang relevan untuk identifikasi flora khas Indonesia. Selain itu, studi tentang pengaruh kombinasi teknik CNN dengan *transfer learning* pada dataset kecil bunga lokal masih terbatas. Perlu dilakukan pengembangan model CNN yang fokus pada identifikasi bunga lokal dengan akurasi tinggi.

Penelitian ini bertujuan untuk mengembangkan model klasifikasi bunga berbasis CNN dengan teknik *transfer learning*, guna meningkatkan efisiensi dan akurasi identifikasi spesies bunga di Indonesia. Selain itu, hasil penelitian ini diharapkan dapat berkontribusi dalam pelestarian keanekaragaman hayati dan meningkatkan kesadaran masyarakat akan pentingnya flora lokal.

2. METODE PENELITIAN

Penelitian ini diawali dengan pengumpulan data citra spesies bunga di Indonesia. Data tersebut dibagi menjadi dua bagian yaitu data untuk melatih model dan data untuk tes model. Kemudian dilakukan *pre-processing* untuk mendapatkan data yang sesuai untuk pelatihan, sehingga dapat meningkatkan akurasi model. Model CNN yang digunakan adalah model *pretrained* yang selanjutnya dilatih menggunakan data latih. Evaluasi dilakukan berdasarkan akurasi model dalam memprediksi label kelas bunga dalam data tes. Tahapan penelitian ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Tabel 1. Konfigurasi arsitektur MobileNet

Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
Conv dw / s1	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
5× Conv / s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$1 \times 1 \times 1024$
Softmax / s1	Classifier	$1 \times 1 \times 1000$

2.1 Pengumpulan data

Data yang digunakan merupakan data sekunder yang diperoleh melalui metode crawling dari mesin pencari Bing. Citra-citra tersebut diberi label berdasarkan spesies bunga yang sesuai dan kemudian diproses untuk memastikan data yang digunakan bersih dan relevan. Data terdiri dari 11 spesies bunga dari Badan Penelitian dan Pengembangan Pertanian Kementerian Pertanian [12] dengan total 2137 citra yang dibagi menjadi 90% untuk data latih dan 10% untuk data test. Data latih akan dibagi lagi menjadi data train dan validation dengan perbandingan 80% dan 20% citra.

2.2 Pre-processing

Pre-processing dalam penelitian ini dilakukan dengan augmentasi data, yaitu teknik untuk memperluas ukuran dataset pelatihan tanpa perlu mengumpulkan data tambahan. Pendekatan ini dapat mengurangi *overfitting*, meningkatkan kemampuan generalisasi terhadap data baru, dan memperbaiki kinerja model. Metode augmentasi yang digunakan dalam penelitian ini meliputi : mengubah ukuran dan normalisasi dengan membagi setiap nilai piksel dengan 255, sehingga rentang intensitas piksel antar 0 hingga 1. Selain itu, teknik *random flip* diterapkan untuk membalik gambar secara acak, baik secara horizontal maupun vertikal. Hal ini membantu model menjadi lebih tahan terhadap perubahan orientasi atau sudut pandang objek dalam data pelatihan. Selain meningkatkan ukuran dataset, penerapan teknik-teknik augmentasi tersebut juga memperkaya variasi dalam data pelatihan. Hal ini penting untuk memastikan model dapat belajar dari berbagai kondisi dan situasi, sehingga dapat beradaptasi dengan lebih baik ketika dihadapkan pada data baru di dunia nyata.

2.3 Model CNN

Penelitian ini menggunakan CNN model MobileNetV2 [13] yang dikenal sebagai model yang memiliki akurasi yang tinggi dan membutuhkan sumber daya komputasi yang relatif lebih ringan. MobileNetV2 mengintegrasikan konvolusi *depth-wise* dan *point-wise*. Konvolusi *depth-wise* mengurangi jumlah parameter dengan menerapkan satu filter konvolusi per saluran input. Selanjutnya, konvolusi *pointwise* digunakan untuk membuat kombinasi linier dari keluaran konvolusi *depth-wise*. Secara keseluruhan arsitektur MobileNet terdiri dari lapisan konvolusi standar, *depthwise*, *pointwise*, *pooling*, dan *softmax* sebagai *classifier*. Susunan dari lapisan-lapisan tersebut ditunjukkan pada Tabel 1 dengan *Conv* adalah konvolusi, *dw* yaitu *depth-wise* dan *s* merupakan *stride*.

Model CNN MobileNetV2 dilatih untuk klasifikasi multikelas menggunakan fungsi *loss* Softmax (L_s) pada Persamaan 1.

$$L_s = -\frac{1}{N} \sum_{i=1}^n \log \left(\frac{e^{f_{yi}}}{\sum_{j=1}^K e^{f_j}} \right) \quad (1)$$

Simbol f_{yi} adalah luaran jaringan *fully-connected* f dari masukan dengan label y_i , sedangkan f_j untuk label j , N adalah jumlah sampel dan K merupakan jumlah total kelas.

2.4 Evaluasi Klasifikasi

Evaluasi hasil klasifikasi citra bertujuan untuk mengukur kinerja model dalam memprediksi kelas citra dengan benar. Parameter utama yang digunakan dalam evaluasi ini adalah akurasi, yang menunjukkan seberapa banyak prediksi model yang sesuai dengan label sebenarnya dari dataset. Akurasi dihitung menggunakan rumus pada Persamaan 2.

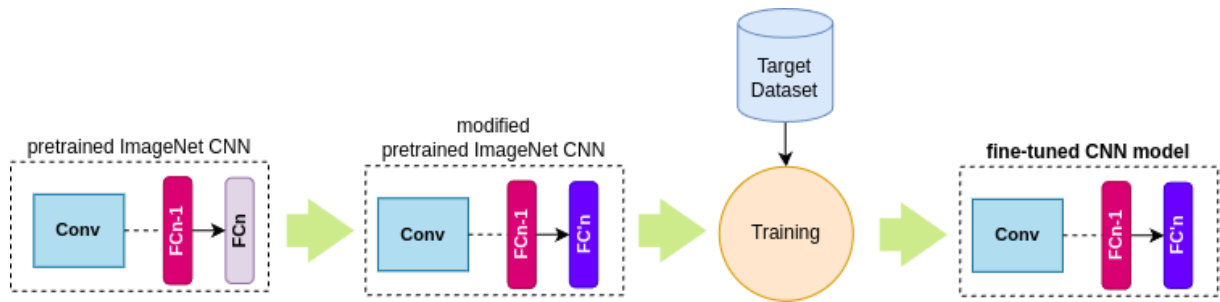
$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Jumlah Total Data}} \times 100\% \quad (2)$$

Pada penelitian ini, dilakukan perbandingan antara model CNN *tanpa transfer learning* dan model CNN dengan *transfer learning*. Evaluasi dilakukan pada data test yang terdiri dari 219 citra dari 11 spesies bunga.

2.5 Transfer Learning

Transfer learning adalah teknik yang digunakan untuk memanfaatkan model yang telah dilatih sebelumnya atau *pre-trained* model pada satu domain untuk menyelesaikan tugas pada domain lain yang serupa [14]. Dalam penelitian ini, *transfer learning* diterapkan untuk mengadaptasi model *pre-trained* ImageNet [15] ke dataset gambar bunga sebagai domain target. Proses ini dimulai dengan mentransfer parameter dari lapisan konvolusi dan *pooling* milik model sumber ke model target. Pendekatan ini dikenal sebagai metode *transfer learning* berbasis jaringan, yang memungkinkan fitur-fitur yang telah dipelajari dari dataset yang lebih umum seperti ImageNet untuk digunakan kembali dalam klasifikasi yang berbeda tetapi relevan [16].

Pada tahap awal, lapisan *fully connected* terakhir (FC_n) dari model sumber digantikan dengan lapisan baru (FC_n'). Lapisan baru ini dirancang khusus untuk menyesuaikan jumlah kelas yang ada dalam dataset gambar bunga. Penggantian ini memungkinkan model beradaptasi dengan mudah untuk klasifikasi dataset target. Setelah itu, dilakukan proses *fine-tuning* pada model, yang melibatkan pelatihan ulang menggunakan dataset gambar bunga. Proses ini bertujuan untuk menyempurnakan dan memperbaiki parameter model agar lebih sesuai dengan karakteristik dataset target. Gambar 2 menunjukkan alur proses *transfer learning* mulai dari model *pre-trained* hingga proses pelatihan ulang pada dataset target [17]. Metode ini memungkinkan fitur-fitur yang telah dipelajari dari dataset besar seperti ImageNet dapat dimanfaatkan, sehingga mengurangi kebutuhan pelatihan dari awal, yang biasanya memerlukan sumber daya komputasi besar.



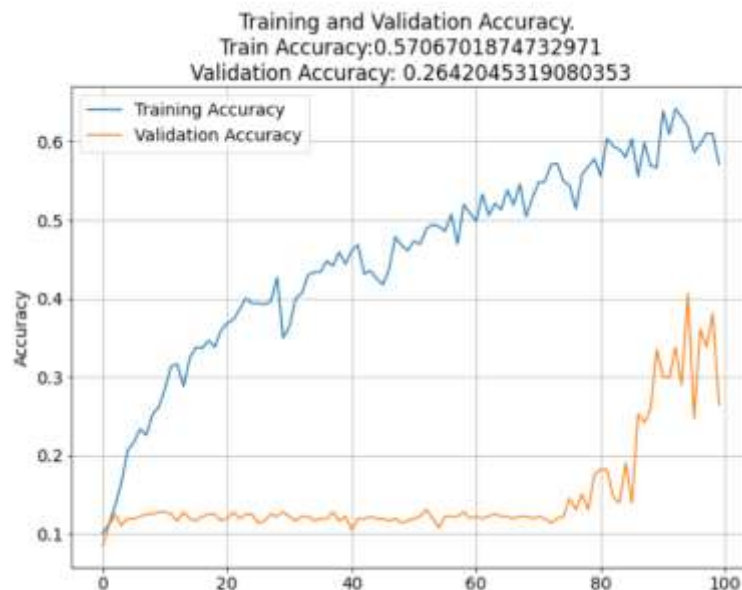
Gambar 2. Proses Transfer Learning Model CNN

3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil penelitian yang diperoleh dari pengujian model klasifikasi citra bunga menggunakan CNN tanpa *transfer learning* dan dengan *transfer learning*. Hasil yang diperoleh akan dibahas dan dianalisis untuk memberikan pemahaman yang lebih mendalam mengenai efektivitas metode yang diterapkan.

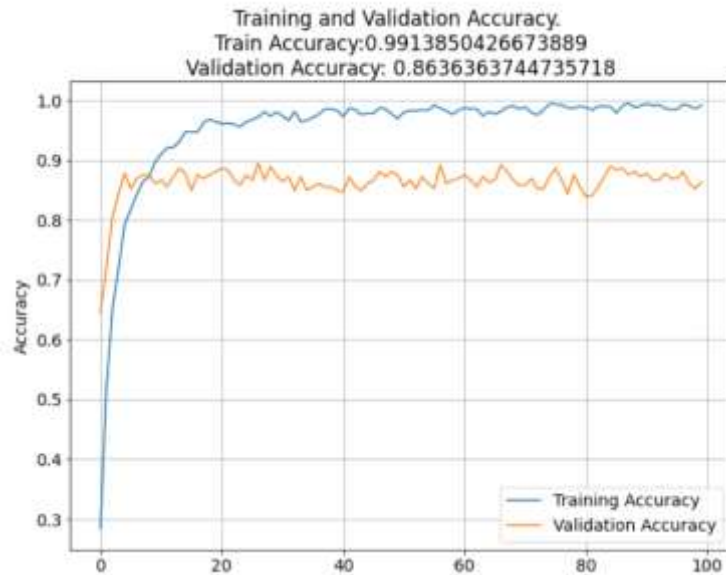
3.1 Hasil Pelatihan Model

Pelatihan model CNN dilakukan pada mesin yang mendukung GPU dengan 100 *epoch*. Pelatihan dioptimalkan dengan algoritma Adam, *learning rate* diatur sebesar 10^{-4} dan menggunakan *batch* berukuran 32. Hasil akurasi training dan validasi untuk setiap *epoch* (1 -100) ditunjukkan dalam grafik pada Gambar 3.



Gambar 3. Grafik akurasi training dan validasi pada MobileNetV2 tanpa transfer learning

Grafik akurasi model tanpa transfer learning di Gambar 3 menunjukkan bahwa nilai akurasi untuk data latih mencapai angka 0.57 (57%) sementara akurasi pada data validasi 0.264 (26.4%). Grafik ini menunjukkan bahwa model CNN tanpa transfer learning membutuhkan lebih banyak data atau pelatihan lebih lanjut agar dapat menghasilkan kinerja yang optimal. Perbedaan besar antara akurasi data latih dan validasi juga mengindikasikan *overfitting*, di mana model terlalu menyesuaikan diri dengan data latih tetapi tidak mampu melakukan generalisasi dengan baik pada data validasi. Hal ini dapat terjadi karena model tanpa *transfer learning* memulai pelatihan dari awal (*training from scratch*), sehingga sulit untuk memperoleh hasil optimal dengan dataset yang terbatas.



Gambar 4. Grafik akurasi training dan validasi pada MobileNetV2 dengan transfer learning

Gambar 4 merupakan grafik akurasi model dengan *transfer learning* yang menunjukkan hasil yang lebih baik dibandingkan dengan tanpa *transfer learning*. Akurasi data latih mencapai 0.991 (99.1%) dan akurasi data validasi mencapai 0.863 (86.3%). Kinerja yang lebih baik ini disebabkan oleh penggunaan model *pre-trained* dari MobileNetV2 dengan bobot dari ImageNet. *Transfer learning* membantu model memulai pelatihan dari bobot awal yang sudah dilatih pada dataset ImageNet, sehingga model dapat lebih cepat mencapai konvergensi dengan akurasi yang tinggi. Kesenjangan akurasi antara data latih dan validasi juga lebih kecil, menunjukkan bahwa model dapat melakukan generalisasi dengan lebih baik.



Gambar 5. Grafik loss training dan validasi pada MobileNetV2 tanpa transfer learning

Grafik *loss* model tanpa *transfer learning* di Gambar 5 memperlihatkan nilai *loss* untuk data latih adalah 1.152, sementara data validasi memiliki nilai *loss* yang lebih tinggi, yaitu 5.458. Nilai *loss* yang tinggi pada data validasi menunjukkan bahwa model kesulitan belajar pola dari data yang tidak terlihat sebelumnya. Tingginya nilai *loss* ini juga menunjukkan bahwa model memerlukan lebih banyak data pelatihan atau peningkatan arsitektur untuk mengurangi kesalahan prediksi.



Gambar 6. Grafik loss training dan validasi pada MobileNetV2 dengan transfer learning

Grafik loss model dengan transfer learning di Gambar 6 menunjukkan nilai loss untuk data latih adalah 0.034, sementara data validasi memiliki nilai *loss* sebesar 0.682. Nilai *loss* yang lebih rendah ini menunjukkan bahwa *transfer learning* mempercepat proses pelatihan dan meningkatkan kemampuan model dalam mempelajari pola dari dataset. *Loss* yang lebih rendah mengindikasikan model dapat menghasilkan prediksi yang lebih akurat dan memiliki tingkat kesalahan yang lebih kecil.

Grafik akurasi dan loss menunjukkan bahwa model dengan *transfer learning* secara signifikan lebih unggul dibandingkan model tanpa *transfer learning*. *Transfer learning* memungkinkan penggunaan fitur-fitur yang telah dipelajari dari dataset besar seperti ImageNet untuk diaplikasikan pada dataset yang lebih kecil seperti dataset bunga di penelitian ini. Hal ini mengurangi kebutuhan pelatihan dari awal, menghemat waktu komputasi, dan meningkatkan akurasi model baik pada data latih maupun data validasi.

3.2 Hasil Pengujian Model

Tahap pengujian data adalah tahap untuk pengujian data test menggunakan aplikasi untuk proses pengujiannya. Pengujian dilakukan dengan menggunakan sampel sebanyak 219 gambar yang terbagi dari 11 kategori bunga. Pengujian ini dilakukan untuk memastikan apakah akurasi yang didapatkan dari proses pembelajaran CNN mempunyai nilai akurasi yang sesuai atau tidak jika dilakukan pengujian terhadap data tes yang kemudian dicatat setiap prediksi dari output aplikasi dan dihitung nilai akurasi dari setiap kategori pada data test. Model CNN MobileNetV2 diimplementasikan kedalam aplikasi di *smartphone*. Kemudian aplikasi dijalankan menggunakan kamera dari *smartphone* untuk melakukan pemindaian obyek bunga pada data tes yang akan diklasifikasi. Gambar 7 menunjukkan contoh tampilan aplikasi saat dilakukan pengujian data tes.

Nilai akurasi yang diperoleh dari pengujian sampel bunga di setiap kategori pada data uji ditampilkan pada Tabel 2. Berdasarkan pengujian dataset yang terdiri dari 1539 citra sebagai data pelatihan, 379 citra sebagai data validasi, dan 219 citra sebagai data pengujian dari 11 kategori bunga, dilakukan analisis menggunakan model CNN tanpa transfer learning dan dengan transfer learning. Hasilnya menunjukkan bahwa metode transfer learning menghasilkan akurasi sebesar 84% pada data validasi, sedangkan tanpa transfer learning hanya mencapai 32%, sehingga terdapat perbedaan akurasi sebesar 52% yang lebih baik dengan transfer learning. Pada pengujian data uji menggunakan model yang diimplementasikan pada *smartphone*, diperoleh akurasi sebesar 42% tanpa transfer learning dan meningkat menjadi 73% dengan transfer learning.

Tabel 2. Hasil Pengujian Data Tes

Spesies Bunga	Total Citra	Dengan Transfer Learning (Benar)	Akurasi (%) Dengan Transfer Learning	Tanpa Transfer Learning (Benar)	Akurasi (%) Tanpa Transfer Learning
Anggrek Dendrobium	25	17	68%	8	32%
Anggrek Phalaenopsis	23	22	95%	15	65%
Anggrek Spathoglottis	13	4	30%	3	23%

Anthurium	27	24	88%	12	44%
Anyelir	21	16	76%	5	24%
Gerbera	21	16	76%	14	66%
Gladiolus	17	11	64%	5	29%
Krisan	18	13	72%	5	27%
Lili	21	13	61%	9	42%
Mawar	16	16	100%	7	44%
Sedap Malam	17	13	76%	12	70%
Rata-rata Akurasi			73%		42%



Gambar 7. Tampilan aplikasi pengujian data tes.

4. KESIMPULAN

Penelitian ini menggunakan model CNN dengan arsitektur MobileNetV2 untuk klasifikasi citra bunga. Hasil pengujian menunjukkan bahwa model tanpa *transfer learning* menghasilkan akurasi 57% untuk data *training*, 32% untuk data validasi, dan 42% untuk data tes. Model dengan *transfer learning* mencapai akurasi 99% untuk data *training*, 86% untuk data validasi, dan 73% untuk data tes. Hal ini menunjukkan bahwa *transfer learning* secara signifikan meningkatkan akurasi dalam klasifikasi dibandingkan dengan model CNN tanpa *transfer learning*. *Transfer learning* memanfaatkan *pre-trained* model dari ImageNet, sehingga model tidak perlu dilatih ulang secara penuh, sementara model tanpa *transfer learning* melatih bobotnya langsung menggunakan dataset penelitian. Oleh karena itu, implementasi *transfer learning* terbukti efektif dalam meningkatkan akurasi dan efisiensi pelatihan model klasifikasi citra spesies bunga di Indonesia.

DAFTAR PUSTAKA

- [1] A. Setiawan, “Keanekaragaman hayati Indonesia: Masalah dan upaya konservasinya,” *Indones. J. Conserv.*, vol. 11, no. 1, pp. 13–21, 2022.
- [2] S. Mishra, R. Sachan, and D. Rajpal, “Deep convolutional neural network based detection system for real-time corn plant disease recognition,” *Procedia Comput. Sci.*, vol. 167, pp. 2003–2010, 2020.
- [3] J. Gupta, S. Pathak, and G. Kumar, “Deep learning (CNN) and transfer learning: a review,” in *Journal of Physics: Conference Series*, IOP Publishing, 2022, p. 012029.
- [4] M. Prasad *et al.*, “An efficient classification of flower images with convolutional neural networks,” *Int. J. Eng. Technol.*, vol. 7, p. 384, 2017, doi: 10.14419/IJET.V7I1.1.9857.
- [5] A. Peryanto, A. Yudhana, and R. Umar, “Convolutional Neural Network and Support Vector Machine in Classification of Flower Images,” *Khazanah Inform. J. Ilmu Komput. Dan Inform.*, 2022, doi: 10.23917/khif.v8i1.15531.
- [6] F. Gu, “Intelligent flower recognition system based on deep learning,” in *Third International Conference on Artificial Intelligence and Electromechanical Automation (AIEA 2022)*, S. Yang and G. Wu, Eds., SPIE, 2022, p. 1232903. doi: 10.1117/12.2646860.
- [7] S. Islam, M. F. A. Foysal, and N. Jahan, “A Computer Vision Approach to Classify Local Flower using Convolutional Neural Network,” *2020 4th Int. Conf. Intell. Comput. Control Syst. ICICCS*, pp. 1200–1204, 2020, doi: 10.1109/ICICCS48265.2020.9121143.
- [8] T. Karahan and V. Nabiyeu, “Plant identification with convolutional neural networks and transfer learning,” *Pamukkale Üniversitesi Mühendis. Bilim. Derg.*, vol. 27, no. 5, pp. 638–645, 2021.
- [9] S. Desai, C. Gode, and P. Fulzele, “Flower Image Classification Using Convolutional Neural Network,” *2022 First Int. Conf. Electr. Electron. Inf. Commun. Technol. ICEEICT*, pp. 1–4, 2022, doi: 10.1109/ICEEICT53079.2022.9768635.
- [10] J. Sumpena, “A Comparative study of Transfer Learning CNN for Flower Type Classification,” *J. Appl. Intell. Syst.*, vol. 8, no. 3, pp. 389–399, 2023.
- [11] I. Anjani, Y. Pratiwi, and N. Bagas, “Implementation of Deep Learning Using Convolutional Neural Network Algorithm for Classification Rose Flower,” *J. Phys. Conf. Ser.*, vol. 1842, 2021, doi: 10.1088/1742-6596/1842/1/012002.
- [12] R. Soehendi, B. Marwoto, K. Budiarto, S. Kartikaningrum, and K. Yuniarto, *Katalog Varietas Unggul Florikultura*. Badan Penelitian dan Pengembangan Pertanian Kementerian Pertanian, 2015.
- [13] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [14] J. Gupta, S. Pathak, and G. Kumar, “Deep learning (CNN) and transfer learning: a review,” in *Journal of Physics: Conference Series*, IOP Publishing, 2022, p. 012029.
- [15] O. Russakovsky *et al.*, “ImageNet Large Scale Visual Recognition Challenge,” *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, Dec. 2015, doi: 10.1007/s11263-015-0816-y.
- [16] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, and C. Liu, “A survey on deep transfer learning,” *Lect. Notes Comput. Sci. Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinforma.*, vol. 11141 LNCS, pp. 270–279, 2018, doi: 10.1007/978-3-030-01424-7_27.
- [17] A. Rahman, E. Winarko, and K. Mustofa, “Content-based product image retrieval using squared-hinge loss trained convolutional neural networks,” *Int. J. Electr. Comput. Eng. IJECE*, vol. 13, no. 5, pp. 5804–5812, 2023.