

Analisis Komparasi Model Deep Learning CNN dengan VGG16 dalam Klasifikasi Jenis Bunga

Nelson Rumui ¹, Ardhyansyah Mualo ², Jacob Rahayaan ³,
Lourdes Batjo ⁴, Misael Mokansi ⁵

^{1,2} Manajemen Informatika, Politeknik Negeri Fakfak

Jl. Imam Bonjol, Tanama, Kecamatan Fakfak 98611, Kabupaten Fakfak, Papua Barat.

^{3,4,5} Program Studi Teknik Informatika / Fakultas Teknik

Universitas Sam Ratulangi

Jl. Kampus UNSRAT Bahu, Kecamatan Malalayang 95115, Kota Manado, Sulawesi Utara

email: nelsonrumui@gmail.com¹, mualoardhyansyah@gmail.com²,

jacobrahayaan026@student.unsrat.ac.id³, lourdesbatjo026@student.unsrat.ac.id⁴,

misaelmokansi026@student.unsrat.ac.id⁵

Abstrak. Klasifikasi citra bunga merupakan tantangan penting dalam visi komputer karena citra bunga memiliki tingkat variasi yang tinggi dalam hal bentuk, warna, latar belakang, dan sudut pengambilan gambar, yang sering kali menyulitkan proses klasifikasi secara akurat. Permasalahan ini mendorong dilakukannya penelitian untuk mengembangkan dan membandingkan efektivitas dua pendekatan deep learning, yaitu arsitektur Convolutional Neural Network (CNN) yang dibangun dari awal dan model VGG16 pre-trained yang diterapkan melalui metode transfer learning. Tujuan dari penelitian ini adalah untuk mengevaluasi kinerja kedua model dalam mengklasifikasikan lima jenis bunga daisy, dandelion, rose, sunflower, dan tulip berdasarkan akurasi, efisiensi pelatihan, dan kemampuan generalisasi. Dataset yang digunakan bersifat open-source dan diperoleh dari platform Kaggle, kemudian dibagi menjadi data pelatihan dan pengujian. Hasil eksperimen menunjukkan bahwa model CNN standar hanya mencapai akurasi sebesar 48%, sementara model berbasis VGG16 mencapai akurasi hingga 90%. Temuan ini menegaskan bahwa transfer learning dengan VGG16 merupakan pendekatan yang lebih unggul dan efektif untuk tugas klasifikasi citra bunga, terutama dalam skenario yang menuntut akurasi tinggi. Penelitian ini memberikan wawasan penting bagi pengembangan sistem klasifikasi visual berbasis deep learning.

Kata Kunci: CNN, VGG16, Klasifikasi Citra Digital, Deep Learning

1 Pendahuluan

Indonesia adalah negara dengan keanekaragaman hayati yang sangat tinggi, termasuk kekayaan spesies bunga yang tersebar di berbagai ekosistem tropis. Dengan kondisi geografis dan iklim yang mendukung pertumbuhan flora, Indonesia memiliki banyak jenis bunga yang memiliki potensi besar dalam sektor pertanian, hortikultura, obat-obatan, hingga pariwisata. Meskipun beberapa bunga memiliki ciri khas yang unik, banyak pula yang memiliki kemiripan bentuk, warna, dan struktur sehingga sulit dibedakan secara visual, terutama oleh orang awam. Proses identifikasi manual terhadap jenis bunga memerlukan pengetahuan botani yang mendalam dan keterampilan khusus, serta memakan waktu dan sumber daya besar. Selain itu, tantangan teknis seperti variasi pencahayaan, latar belakang, dan sudut pengambilan gambar membuat proses ini semakin sulit.

Perkembangan teknologi kecerdasan buatan, khususnya dalam bidang computer vision, menawarkan solusi yang lebih efisien dan akurat melalui pendekatan deep learning. Salah satu metode yang paling banyak digunakan adalah Convolutional Neural Network (CNN), arsitektur jaringan saraf tiruan yang sangat efektif dalam mengenali pola visual dari citra digital tanpa ekstraksi fitur manual. CNN mampu mengenali fitur kompleks dan melakukan klasifikasi dengan akurasi tinggi, menjadikannya sangat cocok untuk pengenalan objek seperti citra bunga. Beberapa penelitian di Indonesia telah berhasil mengimplementasikan CNN untuk klasifikasi bunga, seperti yang dilakukan oleh Betty (2024) dengan akurasi mencapai 99,30% [1], serta

Setiawan (2023) yang menggunakan MobileNetV2 dengan akurasi 86% [2]. Puspitasari (2021) juga berhasil mengklasifikasikan bunga anggrek genus *Grammatophyllum* menggunakan CNN [3], sementara Rahmadhani dan Marpaung (2023) menunjukkan fleksibilitas CNN dalam klasifikasi jamur [4].

Penelitian lain menyoroti pentingnya data augmentation dan fine-tuning dalam meningkatkan performa CNN, seperti yang dilakukan oleh Sasongko dan Amrullah (2023) [5], serta Fitriani (2021) yang menunjukkan kemampuan CNN membedakan bunga dari latar belakang kompleks [6]. Sibarani (2023) juga menunjukkan hasil memuaskan dalam klasifikasi tanaman hias menggunakan CNN [7]. Selain CNN standar, pendekatan transfer learning menggunakan model pretrained seperti VGG16 juga telah diteliti. Pratiwi et al. (2021) membandingkan CNN dengan VGG16 dan menemukan bahwa model pretrained lebih efisien dan akurat [8]. Peryanto et al. (2022) membandingkan CNN dengan SVM dan menemukan bahwa CNN unggul dalam presisi dan recall [9]. Sumpena (2023) membandingkan beberapa arsitektur CNN dan mendapati DenseNet sebagai yang terbaik dalam dataset terbatas [10], sedangkan Predianto (2022) menunjukkan pentingnya augmentasi untuk menghadapi latar belakang dan pencahayaan yang bervariasi [11]. Perwati (2024) juga menekankan pengaruh sudut pengambilan gambar terhadap performa CNN [12].

Secara global, efektivitas VGG16 dalam klasifikasi bunga juga telah banyak dibuktikan. Sahili berhasil meningkatkan akurasi secara signifikan dengan menerapkan teknik augmentasi data pada VGG16 [13], dan Khadangi menunjukkan bahwa model ini memiliki performa lebih baik dibanding CNN konvensional [14]. Namun demikian, sebagian besar penelitian tersebut masih memiliki keterbatasan, seperti fokus hanya pada jenis bunga tertentu, penggunaan dataset yang terbatas, serta belum mengatasi tantangan variasi kondisi nyata seperti pencahayaan, latar belakang, dan sudut gambar. Oleh karena itu, penelitian ini bertujuan untuk menganalisis efektivitas CNN dan VGG16 dalam mengklasifikasikan lima jenis bunga—daisy, dandelion, rose, sunflower, dan tulip—dengan mempertimbangkan variabilitas visual. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem klasifikasi bunga otomatis yang efisien, akurat, dan andal, serta bermanfaat dalam berbagai sektor seperti pertanian presisi, konservasi, dan pendidikan.

2 Metodologi Penelitian

2.1. Tinjauan Pustaka

2.1.1. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan teknik utama dalam visi komputer untuk tugas klasifikasi gambar dan pengenalan objek, dengan kemampuan mengekstraksi fitur secara otomatis melalui lapisan konvolusi, pooling, dan fully connected [15]. Model seperti ResNet, DenseNet, dan VGG16 terbukti unggul dalam kompetisi seperti ImageNet. CNN juga telah diterapkan dalam klasifikasi gambar bunga, seperti pada penelitian Nidhi (2020) yang menunjukkan akurasi tinggi meskipun dalam kondisi pencahayaan dan latar belakang yang kompleks [16]. Selain itu, teknik transfer learning dengan model pra-latih seperti VGG16 semakin populer karena mampu meningkatkan akurasi dan efisiensi pelatihan, sebagaimana dibuktikan oleh Noprisson (2022) meskipun menggunakan dataset terbatas [17].

2.1.2. Klasifikasi Citra Digital

Klasifikasi citra digital adalah proses pengelompokan citra berdasarkan fitur atau karakteristik yang terkandung di dalamnya. Dalam klasifikasi citra, setiap citra atau objek dalam citra dikelompokkan ke dalam kategori yang telah ditentukan sebelumnya berdasarkan informasi visual yang tersedia. Klasifikasi citra memiliki aplikasi yang luas, termasuk dalam bidang medis, pertanian, serta pengawasan dan pengendalian kualitas di industri. Salah satu teknik yang paling populer dalam klasifikasi citra digital adalah penggunaan algoritma machine learning dan deep learning, yang mampu mengidentifikasi dan mengekstraksi fitur-fitur penting secara otomatis [18].

2.1.3. Deep Learning

Deep learning adalah cabang dari machine learning yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan untuk memproses dan mengekstraksi fitur dari data dalam jumlah besar. Model ini, terutama Convolutional Neural Networks (CNN), telah menunjukkan hasil yang luar biasa dalam

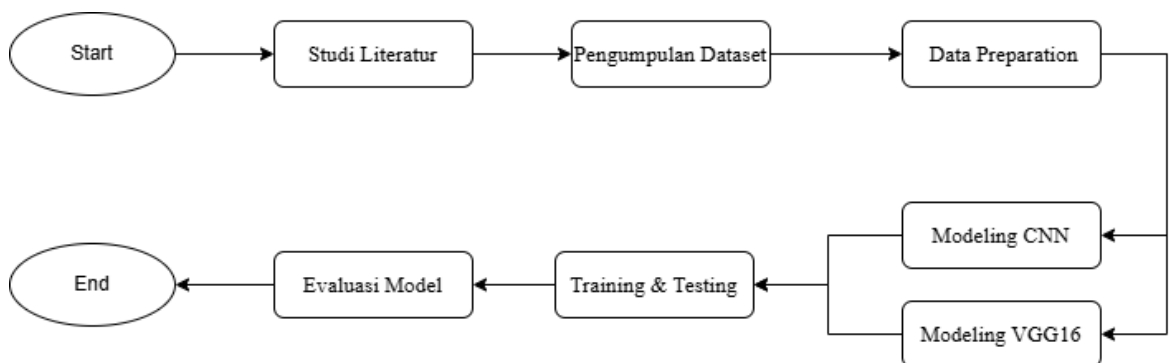
berbagai aplikasi seperti pengenalan citra, analisis suara, dan pemrosesan bahasa alami. CNN mengurangi kebutuhan untuk ekstraksi fitur manual dan memungkinkan model untuk belajar representasi fitur secara otomatis dari data mentah [19]. Dalam beberapa tahun terakhir, penerapan deep learning di berbagai bidang telah menunjukkan kemajuan yang signifikan. Misalnya, dalam bidang medis, CNN telah digunakan untuk pengklasifikasian citra medis dengan hasil yang lebih baik dibandingkan teknik konvensional. Penelitian oleh Rehman (2021) menunjukkan bagaimana CNN dapat diterapkan dalam analisis gambar medis untuk deteksi penyakit, memberikan hasil yang lebih akurat dan cepat daripada metode sebelumnya [20].

2.1.4. VGG16

VGG16 adalah salah satu arsitektur jaringan saraf dalam (deep neural network) yang telah terbukti sangat efektif dalam tugas-tugas pengenalan citra. Dikenalkan oleh Simonyan dan Zisserman pada tahun 2014, model ini memiliki 16 lapisan (13 lapisan konvolusi dan 3 lapisan fully connected) yang terdiri dari lapisan-lapisan konvolusi berukuran kecil (3x3) dan lapisan pooling. Keunggulan utama dari VGG16 adalah kesederhanaannya yang memungkinkan pemrosesan citra dengan ukuran resolusi tinggi dan akurasi yang sangat baik dalam klasifikasi citra besar [21]. Dalam beberapa tahun terakhir, VGG16 telah banyak digunakan dalam transfer learning untuk tugas klasifikasi citra, termasuk dalam aplikasi medis, pengenalan objek, dan bidang lainnya. Penelitian oleh Sulistyowati (2023) menunjukkan bahwa VGG16 yang dilatih dengan dataset besar dapat dengan mudah diadaptasi untuk pengenalan gambar spesifik, seperti dalam klasifikasi tanaman, dengan hasil yang sangat baik meskipun menggunakan dataset yang lebih kecil untuk fine-tuning [22]. Meskipun berbagai penelitian telah menunjukkan keberhasilan CNN dan model pre-trained seperti VGG16 dalam klasifikasi citra secara umum, masih terdapat keterbatasan dalam studi yang secara langsung membandingkan performa CNN yang dibangun dari awal dengan pendekatan transfer learning menggunakan VGG16 secara spesifik pada domain klasifikasi citra bunga. Sebagian besar studi sebelumnya berfokus hanya pada penerapan salah satu metode tanpa perbandingan langsung dalam konteks dan dataset yang sama. Oleh karena itu, penelitian ini bertujuan untuk mengisi celah tersebut dengan melakukan evaluasi komprehensif terhadap kedua pendekatan menggunakan dataset yang seragam dan matrik evaluasi yang konsisten, guna memberikan pemahaman yang lebih jelas mengenai kelebihan dan kekurangan masing-masing metode dalam klasifikasi citra bunga.

2.2. Metodologi Penelitian

Alur penelitian merupakan tahapan sistematis yang dilakukan dalam proses klasifikasi citra bunga menggunakan metode Deep Learning. Dalam penelitian ini, digunakan arsitektur VGG16 dengan pendekatan transfer learning dan fine-tuning. Gambar 1 menunjukkan flowchart dari enam tahapan utama yang dilakukan dalam penelitian ini, dijelaskan sebagai berikut:



Gambar. 1. Alur penelitian

2.2.1. Studi Literatur

Tahap awal penelitian ini adalah pengumpulan informasi dan referensi ilmiah yang relevan mengenai klasifikasi citra berbasis Deep Learning, khususnya yang menggunakan arsitektur

VGG16. Studi ini mencakup jurnal ilmiah, artikel penelitian, dan dokumentasi resmi terkait CNN, transfer learning, dan penerapan arsitektur VGG dalam klasifikasi citra.

2.2.2. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, yaitu dataset citra bunga yang terdiri dari lima kelas: *daisy*, *rose*, *tulip*, *sunflower*, dan *dandelion*. Dataset ini bersifat open-source dan telah digunakan dalam berbagai studi klasifikasi citra bunga. Setiap kelas terdiri dari ratusan hingga ribuan gambar dengan format JPEG atau PNG. Dataset digunakan sebagai sumber utama dalam pelatihan dan pengujian model klasifikasi citra bunga. Dataset tersebut dapat diakses melalui tautan berikut: <https://www.kaggle.com/datasets/alxmamaev/flowers-recognition/data>.

2.2.3. Data Preparation

Tahap data preparation bertujuan untuk menyiapkan dataset sebelum digunakan dalam proses pelatihan dan pengujian model. Dataset yang digunakan terdiri dari 4.286 citra bunga dari lima kelas, yaitu *daisy*, *rose*, *tulip*, *sunflower*, dan *dandelion*, yang diperoleh dari platform Kaggle. Setiap citra diberi label sesuai nama folder kelasnya, kemudian dilakukan proses pra-pemrosesan berupa resize ke ukuran 224x224 piksel agar sesuai dengan input VGG16, serta rescaling nilai piksel dari rentang 0–255 menjadi 0–1 untuk mempercepat konvergensi selama pelatihan. Selain itu, dilakukan augmentasi data seperti rotasi, zoom, flip horizontal, dan translasi guna memperkaya keragaman citra dan mengurangi risiko overfitting. Label kelas dikonversi ke format one-hot encoding untuk mendukung klasifikasi multi-kelas. Setelah proses pra-pemrosesan, dataset dibagi secara acak menjadi data pelatihan sebanyak 80% (3.429 gambar) dan data pengujian sebanyak 20% (857 gambar) dengan memastikan distribusi kelas yang seimbang di kedua subset, sehingga model dapat belajar dan diuji secara adil dan representatif.

2.2.4. Modeling (CNN tanpa VGG16 dan CNN dengan VGG16)

Pada tahap ini, dua arsitektur model digunakan untuk klasifikasi citra bunga: model CNN standar dan model CNN dengan VGG16. Untuk model CNN tanpa VGG16, arsitektur jaringan saraf dibangun dari awal menggunakan lapisan konvolusi, pooling, dan lapisan fully connected untuk ekstraksi fitur dan klasifikasi. Sedangkan untuk model CNN dengan VGG16, arsitektur VGG16 digunakan sebagai feature extractor dengan bobot pre-trained dari ImageNet, tanpa menggunakan lapisan klasifikasi akhir. Model VGG16 ini kemudian dilengkapi dengan lapisan tambahan berupa Flatten, Dense(256, ReLU), dan Dense(5, Softmax) untuk klasifikasi lima jenis bunga. Kedua model disusun menggunakan API Sequential dari Keras untuk membangun dan melatih model deep learning.

2.2.5. Training & Testing

Proses training pada model CNN dilakukan dalam dua pendekatan, yaitu menggunakan CNN biasa dan CNN dengan transfer learning (VGG16). Pada CNN biasa, seluruh arsitektur jaringan, termasuk lapisan konvolusi, pooling, dan fully connected, dilatih dari awal menggunakan data pelatihan, dengan pembaruan bobot dilakukan melalui algoritma backpropagation dan optimasi. Sedangkan pada CNN dengan VGG16, model memanfaatkan bobot pre-trained dari ImageNet sebagai feature extractor, di mana hanya lapisan klasifikasi yang dilatih terlebih dahulu (transfer learning). Setelah itu, dilakukan fine-tuning dengan mengaktifkan sebagian lapisan VGG16 agar dapat menyesuaikan dengan dataset spesifik (seperti gambar bunga). Evaluasi dilakukan secara berkala menggunakan data validasi untuk memantau akurasi, menghindari overfitting, dan meningkatkan kemampuan generalisasi model, baik untuk CNN biasa maupun model berbasis transfer learning. Secara berkala menggunakan data validasi untuk memantau kinerja model dan menghindari overfitting.

2.2.6. Evaluasi Model

Tahapan terakhir dalam penelitian ini adalah evaluasi performa model menggunakan data pengujian. Matrik evaluasi yang digunakan mencakup akurasi, loss, precision, recall, dan F1-score. Tujuan utama dari penelitian ini adalah untuk mengevaluasi kinerja model dalam mengklasifikasikan lima jenis bunga, yaitu *daisy*, *dandelion*, *rose*, *sunflower*, dan *tulip*, dengan mempertimbangkan variasi pada gambar seperti warna, bentuk, pencahayaan, sudut pengambilan

gambar, dan latar belakang. Penelitian ini secara khusus menguji kemampuan model VGG16, baik dalam arsitektur CNN biasa maupun yang menggunakan transfer learning dengan bobot pre-trained dari ImageNet, untuk mengenali pola visual dari citra bunga. Evaluasi dilakukan dengan mengukur akurasi dan loss, serta metrik tambahan seperti precision, recall, dan F1-score terhadap data pengujian guna menilai kemampuan generalisasi model dan kinerjanya dalam kondisi variatif.

3. Hasil dan Pembahasan

Analisis efektivitas dua pendekatan arsitektur deep learning, yaitu CNN konvensional dan VGG16 pre-trained dengan transfer learning, dalam mengklasifikasikan lima jenis bunga: daisy, dandelion, rose, sunflower, dan tulip. Evaluasi kinerja model dilakukan berdasarkan metrik akurasi dan loss selama pelatihan dan pengujian, dimana akurasi mengukur ketepatan klasifikasi dan loss menunjukkan tingkat kesalahan prediksi. Pelatihan dilakukan selama 10 epoch untuk dua skenario: pelatihan CNN dari awal dan pelatihan VGG16 menggunakan bobot ImageNet. Tujuan utama dari analisis ini adalah untuk menentukan arsitektur mana yang lebih unggul dalam menangani klasifikasi citra bunga yang memiliki kompleksitas visual tinggi.

3.1. Data Preparation dan Modeling

Pada tahap data preparation dan modeling, gambar bunga dikumpulkan dari platform Kaggle dengan lima kelas utama, yaitu *daisy*, *dandelion*, *rose*, *sunflower*, dan *tulip*, dengan total 4.286 gambar. Seluruh gambar diubah ukurannya menjadi 224x224 piksel, dinormalisasi ke rentang [0,1], dan diberi augmentasi sederhana seperti rotasi, flipping, dan zooming untuk meningkatkan keragaman data serta mencegah overfitting. Dua pendekatan pemodelan digunakan dalam penelitian ini, yaitu CNN sederhana yang dibangun dari awal menggunakan beberapa lapisan konvolusi, pooling, dan dense layer, serta model transfer learning menggunakan arsitektur VGG16 pre-trained dari ImageNet. Pendekatan transfer learning ini memanfaatkan fitur visual yang telah dipelajari sebelumnya untuk meningkatkan akurasi klasifikasi, sementara model CNN sederhana diuji sebagai baseline untuk mengukur efektivitas desain model dari awal.



Gambar. 2. Data Preparation Image

3.2. Training & Testing


Untuk memastikan proses pelatihan model berjalan optimal, pengaturan hyperparameter seperti jumlah epoch menjadi hal yang krusial. Dalam penelitian ini, model CNN dasar dan VGG16 sama-sama dilatih selama 10 epoch berdasarkan hasil eksplorasi awal dan tren konvergensi akurasi. Model CNN menunjukkan peningkatan bertahap dengan akurasi pelatihan akhir sebesar 45,27% dan akurasi pengujian 48,03%, meskipun cenderung fluktuatif, tren keseluruhannya tetap meningkat. Sementara itu, model VGG16 memperlihatkan performa yang jauh lebih unggul dengan akurasi pelatihan yang sangat tinggi hingga 99,88% dan akurasi pengujian mencapai 90,16%. Hal ini menunjukkan bahwa transfer learning dengan VGG16 sangat efektif dalam mengenali fitur visual bunga, bahkan sejak epoch awal, serta mampu mempertahankan kestabilan dan generalisasi yang baik terhadap data uji tanpa overfitting. Perkembangan akurasi selama proses pelatihan dapat dilihat pada Tabel 3.

Tabel 3. Training CNN vs VGG6

	CNN	VGG16

	Train Accuracy	Test Accuracy	Train Accuracy	Test Accuracy
Epoch 1	38,85%	43,39%	80,19%	88,54%
Epoch 2	38,72%	43,74%	95,68%	87,62%
Epoch 3	41,56%	46,64%	98,90%	87,73%
Epoch 4	43,67%	48,49%	99,45%	88,19%
Epoch 5	43,32%	45,71%	99,71%	88,66%
Epoch 6	43,80%	49,30%	99,65%	89,12%
Epoch 7	45,18%	47,22%	99,94%	89,93%
Epoch 8	45,10%	46,17%	99,88%	88,54%
Epoch 9	44,80%	49,30%	99,91%	89,35%
Epoch 10	45,27%	48,03%	99,88%	90,16%

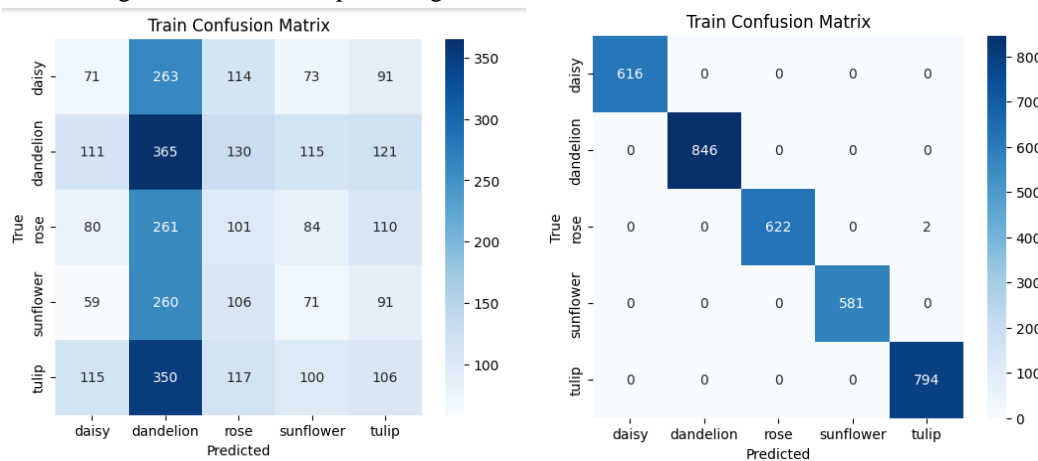
Gambar 3 menunjukkan kurva akurasi pelatihan dan validasi model CNN selama 10 epoch, di mana akurasi pelatihan meningkat secara konsisten dari sekitar 38% pada epoch pertama hingga mendekati 46% pada epoch kesepuluh. Akurasi validasi juga menunjukkan tren positif meskipun sedikit fluktuatif, dengan nilai tertinggi tercapai pada epoch ke-6 dan ke-9 yang mencapai lebih dari 48%. Hal ini menunjukkan bahwa model CNN secara bertahap mampu mempelajari fitur penting dari citra bunga dan memberikan generalisasi yang cukup baik terhadap data baru. Fluktuasi akurasi validasi mencerminkan tantangan dalam mengenali variasi bentuk, warna, dan latar belakang dari gambar bunga. Untuk model VGG16, performa yang jauh lebih stabil dan tinggi ditunjukkan melalui grafik pada Gambar 10, dengan kombinasi terbaik antara training accuracy dan validation accuracy tercatat pada epoch ke-10 dan akurasi tertinggi pada epoch ke-7. Penggunaan fungsi checkpoint dalam pelatihan VGG16 terbukti efektif dalam menyimpan model pada titik kinerja terbaik, sementara grafik pelatihan memperlihatkan peningkatan akurasi dan penurunan loss yang signifikan seiring waktu, menandakan pembelajaran yang efisien dan stabil.



Gambar. 3. Grafik hasil kinerja CNN vs VGG16


4.3 Laporan Evaluasi Model

Confusion matrix hasil pelatihan model CNN menunjukkan bahwa model masih mengalami kesulitan dalam membedakan fitur visual antar kelas bunga, dengan kecenderungan untuk memprediksi sebagian besar gambar sebagai kelas dandelion, termasuk gambar dari kelas daisy, rose, sunflower, dan tulip. Jumlah prediksi benar (nilai diagonal) seperti pada kelas daisy dan sunflower hanya sebesar 71, serta tulip sebesar 106, masih jauh lebih rendah dibandingkan prediksi salah, yang menandakan bahwa model belum mampu menangkap pola spesifik pada masing-masing jenis bunga secara efektif. Sebaliknya, confusion matrix dari model VGG16 memperlihatkan performa klasifikasi yang jauh lebih baik, dengan dominasi angka besar pada diagonal utama, seperti 586 prediksi benar untuk daisy, 863 untuk dandelion, 612 untuk rose, 608 untuk sunflower, dan 782 untuk tulip. Hanya terdapat dua kesalahan prediksi di seluruh data pelatihan, yang menunjukkan tingkat akurasi hampir sempurna. Hal ini membuktikan bahwa pendekatan transfer learning dengan VGG16, ditambah fine-tuning yang sesuai, mampu mengadaptasi bobot model dengan sangat baik terhadap data citra bunga, menjadikannya arsitektur yang andal dan unggul untuk tugas klasifikasi gambar berbasis deep learning.



Gambar. 4. Train confusion matrix CNN vs VGG16

Confusion matrix hasil pengujian model CNN standar menunjukkan bahwa model memiliki keterbatasan dalam membedakan citra bunga antar kelas, dengan kecenderungan klasifikasi yang sangat dominan terhadap kelas dandelion—terlihat dari 159 citra yang diklasifikasikan benar, sementara banyak citra dari kelas lain seperti rose dan tulip justru salah diklasifikasikan ke kelas tersebut. Misalnya, 64 citra rose dan 56 citra tulip salah diprediksi sebagai dandelion, mencerminkan bahwa model CNN konvensional masih kesulitan mengenali perbedaan visual halus antar bunga dengan tekstur dan warna serupa. Sebaliknya, confusion matrix dari hasil pengujian model VGG16 menunjukkan performa klasifikasi yang jauh lebih akurat dengan nilai diagonal yang mendominasi—149 prediksi benar untuk daisy, 181 untuk dandelion, 158 untuk rose, 116 untuk sunflower, dan 175 untuk tulip. Meskipun terdapat beberapa kesalahan, seperti citra daisy dan tulip yang terkadang diklasifikasikan sebagai kelas lain, jumlah kesalahan ini relatif kecil dibanding jumlah prediksi yang benar. Hal ini menandakan bahwa pendekatan transfer learning dengan VGG16 tidak hanya unggul dalam pelatihan, tetapi juga mampu mempertahankan kemampuan generalisasi tinggi saat menghadapi data uji, sehingga menjadikannya pilihan yang lebih handal dibandingkan model CNN standar untuk tugas klasifikasi citra bunga.



Gambar. 5. Test confusion matrix CNN vs VGG16

Hasil evaluasi classification report dari model CNN standar menunjukkan bahwa model hanya mampu mencapai akurasi keseluruhan sebesar 48%, dengan performa yang masih tergolong sedang dan distribusi hasil yang tidak merata di antara lima kelas bunga. Kelas dandelion memiliki recall tertinggi sebesar 0.76, menandakan bahwa sebagian besar gambar dandelion dikenali dengan baik, sementara kelas rose menunjukkan performa terendah dengan recall hanya 0.28, yang mengindikasikan bahwa banyak citra bunga mawar gagal dikenali. Precision tertinggi terdapat pada kelas tulip sebesar 0.65, tetapi disertai dengan recall yang rendah (0.36), mencerminkan bahwa model cukup selektif namun tidak menyeluruh dalam mengenali citra tulip. Nilai macro average dan weighted average untuk precision, recall, dan f1-score berkisar antara 0.47 hingga 0.51, yang menunjukkan bahwa model masih cenderung bias terhadap kelas yang lebih dominan dan belum optimal dalam generalisasi. Sebaliknya, classification report dari model VGG16 pada data uji memperlihatkan hasil yang sangat baik dengan akurasi mencapai 90%. Precision tertinggi diraih oleh kelas daisy (0.96), sedangkan recall tertinggi oleh dandelion (0.96), dan f1-score tertinggi tercatat pada kelas dandelion (0.94). Selain itu, nilai macro average dan weighted average untuk seluruh matrik evaluasi mencapai angka 0.90, menunjukkan performa model yang konsisten dan seimbang di seluruh kelas. Hasil ini menunjukkan bahwa arsitektur VGG16 dengan pendekatan transfer learning secara signifikan lebih unggul dibandingkan model CNN standar, baik dalam hal akurasi, presisi, maupun kemampuan mengenali citra dari berbagai kelas bunga secara umum dan menyeluruh.

Tabel 2. Classification report CNN vs VGG16

	CNN				VGG16			
	Precision	Recall	f1-score	Support	Precision	recall	f1-score	Support
daisy	0.59	0.47	0.52	152	0.96	0.84	0.89	178
dandelion	0.43	0.76	0.54	210	0.91	0.96	0.94	189
rose	0.38	0.28	0.32	158	0.88	0.92	0.90	171
sunflower	0.49	0.48	0.49	146	0.84	0.93	0.88	125
tulip	0.65	0.36	0.46	196	0.91	0.87	0.89	201
accuracy			0.48	864			0.90	864

macro avg	0.51	0.47	0.47	864	0.90	0.90	0.90	864
weighted avg	0.51	0.48	0.47	864	0.90	0.90	0.90	864

4. Kesimpulan dan Saran

Berdasarkan hasil penelitian, arsitektur VGG16 terbukti secara signifikan lebih efektif dibandingkan CNN konvensional dalam klasifikasi citra bunga. Model VGG16 mencapai akurasi pengujian sebesar 90%, jauh lebih tinggi dibandingkan CNN yang hanya memperoleh 48%. Dengan pendekatan transfer learning dan fine-tuning, VGG16 menunjukkan performa unggul pada matrik evaluasi seperti precision, recall, dan f1-score di lima kelas bunga (daisy, dandelion, rose, sunflower, dan tulip). Sebaliknya, CNN konvensional masih kesulitan mengenali pola visual kompleks, terutama pada citra dengan latar belakang rumit atau pencahayaan buruk. Visualisasi kurva akurasi dan confusion matrix memperkuat keunggulan VGG16 dalam menghadapi variasi data, sedangkan CNN mencatat tingkat kesalahan tinggi, khususnya pada kelas dandelion dan tulip. Oleh karena itu, saran yang dapat diberikan untuk penelitian selanjutnya adalah menguji model lain seperti EfficientNet, Inception, atau DenseNet yang mungkin dapat memberikan akurasi lebih tinggi dan efisiensi yang lebih baik. Selain itu, penggabungan teknik object detection dapat menjadi alternatif untuk memungkinkan model mengenali lebih dari satu objek bunga dalam satu gambar dan meningkatkan kemampuan sistem dalam skenario dunia nyata. Penambahan variasi data melalui augmentasi lanjutan atau pengumpulan dataset yang lebih representatif juga dapat membantu meningkatkan generalisasi model secara signifikan.

Referensi

- [1] B. Suswati, "Implementasi Convolutional Neural Network pada Klasifikasi Citra Daun Tanaman Hias," *Jurnal Decode*, vol. 4 No. 2, 2024. <https://doi.org/10.51454/decode.v4i2.590>
- [2] A. Rahman, M. Salim, dan I. Riadi, "Klasifikasi Citra Spesies Bunga di Indonesia Berbasis Convolutional Neural Network Menggunakan Teknik Transfer Learning," *Journal of Software Engineering and Computational Intelligence*, Vol. 2 No. 02, 2024. <https://doi.org/10.36982/jseci.v2i02.4942>
- [3] Puspitasari dan A.T Wibowo, "Klasifikasi Bunga Anggrek untuk Genus *Grammatophyllum* Menggunakan Metode Convolutional Neural Network (CNN)," *e-Proceeding of Engineering*, vol. 8, no. 5, hlm. 10527, 2021. <https://repository.telkomuniversity.ac.id/pustaka/172357/klasifikasi-bunga-anggrek-untuk-genus-grammatophyllum-menggunakan-metode-convolutional-neural-network-cnn-.html>
- [4] U. S. Rahmadhani dan N. L. Marpaung, "Klasifikasi Jamur Berdasarkan Genus Dengan Menggunakan Metode CNN," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 8, 2023. <https://doi.org/10.30591/jpit.v8i2.5229>
- [5] A. Munandar dan A.F Rozi, "Analisis Arsitektur Convolutional Neural Network Untuk Klasifikasi Citra Bunga" *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 6, no. 3, hlm. 522–531, 2024. <https://doi.org/10.47233/jteksis.v6i3.1413>
- [6] F. Fitriani, "Klasifikasi Jenis Bunga dengan Menggunakan Convolutional Neural Network (CNN)," *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, vol. 2, no. 2, hlm. 64–68, 2021. <https://doi.org/10.46764/teknimedia.v2i2.39>
- [7] Sibarani, J. S., Damanik, S. T., Nurkhalizah, R., Mulyana, S., & Nasution, B., "Klasifikasi Tanaman Hias Menggunakan Algoritma Convolutional Neural Network," *Journal of Information Technology Ampera*, vol. 4, no. 3, hlm. 286–297, 2023. <https://journal-computing.org/index.php/journal-ita/article/view/431>
- [8] H. A. Pratiwi, M. Cahyanti, dan M. Lamsani, "Implementasi deep learning flower scanner menggunakan metode convolutional neural network," *Sebatik*, vol. 25, no. 1, pp. 124–130, 2021, doi: <https://jurnal.wicida.ac.id/index.php/sebatik/article/view/1297>
- [9] A. Peryanto, A. Yudhana, dan R. Umar, "Convolutional Neural Network and Support Vector Machine in Classification of Flower Images," *Khazanah Informatika: Jurnal Ilmu Komputer dan Informatika*, vol. 8, no. 1, hlm. 1–8, 2022. <https://doi.org/10.23917/khif.v8i1.15531>
- [10] J. Sumpena, "A Comparative Study of Transfer Learning CNN for Flower Type Classification" *Journal of Applied Intelligent System*, vol. 8, no. 3, hlm. 389–399, 2023. <https://doi.org/10.33633/jais.v8i3.9380>

- [11] E. Predianto dan B. Sutomo, "Klasifikasi Jenis Bunga dengan Algoritma Convolutional Neural Network (CNN) Menggunakan Metode Region-Based Convolutional Neural Network (R-CNN)," *Cyberspace: Jurnal Pendidikan Teknologi Informasi*, vol. 8, no. 2, pp. 1–15, 2024. <https://doi.org/10.22373/cj.v8i2.25441>
- [12] I. G. Perwati, N. Suarna, dan T. Suprpti, "Analisis Klasifikasi Gambar Bunga Lily Menggunakan Metode Convolutional Neural Network (CNN) dalam Pengolahan Citra," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 3, pp. 2908–2915, 2024. <https://doi.org/10.36040/jati.v8i3.9193>
- [13] Z. A. Sahili and M. Awad, "The Power of Transfer Learning in Agricultural Applications: AgriNet," arXiv preprint arXiv:2207.03881, 2022. [Online]. Available: <https://arxiv.org/abs/2207.03881>
- [14] A. Khadangi, "DeepFlorist: Rethinking Deep Neural Networks and Ensemble Learning as a Meta-Classifer for Object Classification," *Computers and Electronics in Agriculture*, vol. 206, p. 107635, 2023. [Online]. Available: <https://doi.org/10.48550/arXiv.2307.01806>
- [15] S. Anand, K. Swaroopa, M. Nainwal, dan T. M, "An intelligent flower classification framework: optimal hybrid flower pattern extractor with adaptive dynamic ensemble transfer learning-based convolutional neural network," *The Imaging Science Journal*, vol. 72, no. 3, hlm. 52–75, 2023 <https://doi.org/10.1080/13682199.2023.2183317>
- [16] N. Nidhi, J. K. P. S. Yadav, "Plant leaf classification using convolutional neural network," *Recent Advances in Computer Science and Communications*, vol. 13, no. 3, 2020, doi: https://www.researchgate.net/publication/344563512_Plant_Leaf_Classification_using_Convolutional_Neural_Network
- [17] H. Noprisson, "Fine-tuning model transfer learning VGG16 untuk klasifikasi citra penyakit tanaman padi," *JSAI (Journal of Scientific and Applied Informatics)*, vol. 5, no. 3, pp. 244–249, Nov. 2022, doi: <https://doi.org/10.36085/jsai.v5i3.3609>
- [18] K. Sanghvi, A. Aralkar, S. Sanghvi, dan I. Saha, "A survey on image classification techniques," *SSRN Electronic Journal*, Jan. 2021, doi: <https://doi.org/10.2139/ssrn.3754116>
- [19] Y. Huang, "Deep learning in image recognition," *Applied and Computational Engineering*, vol. 8, no. 1, pp. 61–67, Aug. 2023, doi: <https://doi.org/10.54254/2755-2721/8/20230082>.
- [20] A. Rehman, M. A. Butt, dan M. Zaman, "A survey of medical image analysis using deep learning approaches," in *Proc. 5th Int. Conf. on Advances in Computing, Communications, and Electronics (ICACCE)*, 2021. doi: <https://doi.org/10.1109/ICCMC51019.2021.9418385>
- [21] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *International Conference on Learning Representations (ICLR)*, 2015. <https://arxiv.org/abs/1409.1556>
- [22] T. Sulistyowati, P. Purwanto, F. A. Zami, dan R. A. Pramunendar, "VGG16 deep learning architecture using imbalance data methods for the detection of apple leaf diseases," *Moneter: Jurnal Keuangan dan Perbankan*, vol. 11, no. 1, pp. 41–53, 2023. <https://ejournal2.uika-bogor.ac.id/index.php/MONETER/article/download/57/48/130>