

KLASIFIKASI JENIS TANAMAN ANGGREK MENGGUNAKAN ARSITEKTUR MOBILENETV2

A. A. Dea Karista Dewi¹, Luh Joni Erawati Dewi², Ni Wayan Marti³

^{1,2,3} Program Studi Ilmu Komputer, Universitas Pendidikan Ganesha

Jl. Udayana No.11, Singaraja, Kabupaten Buleleng, Bali 81116

¹dea@student.undiksha.ac.id, ²joni.erawati@undiksha.ac.id, ³wayan.marti@undiksha.ac.id

Abstract

Orchids are a type of ornamental plant rich in unique flower shapes, colors, and sizes. The large number of orchid species makes direct identification often difficult and generally requires specialized skills and experience. Therefore, an automated method is needed to make orchid species recognition more practical and efficient. In this study, a deep learning-based orchid image classification system was developed using the MobileNetV2 architecture. The dataset used was 2,500 images classified into five categories: *Cattleya*, *Dendrobium*, *Oncidium*, *Phalaenopsis*, and *Vanda*. Model training was carried out through several variations of hyperparameter settings, such as batch sizes of 16 and 32, and the number of epochs of 25 and 50, with a learning rate set at 0.001. Meanwhile, model evaluation was carried out using a confusion matrix with metrics of accuracy, precision, recall, and F1-score. The test results show that optimal performance was achieved using a batch size of 32 and epochs of 50, with accuracy, precision, recall, and F1-score values reaching 99.60%. These findings confirm that hyperparameter variations affect model performance, and MobileNetV2 is capable of providing high and stable classification performance. This research contributes to providing an effective orchid image classification method and demonstrates that selecting the right hyperparameters can significantly improve model performance.

Keywords: Orchid, Image Classification, Deep Learning MobileNetV2, Hyperparameters.

Abstrak

Anggrek adalah jenis tanaman hias yang kaya akan keragaman bentuk, warna, serta ukuran bunganya yang unik. Banyaknya jenis anggrek membuat identifikasi secara langsung sering kali menyulitkan dan umumnya membutuhkan kemampuan serta pengalaman khusus. Oleh karena itu, dibutuhkan cara otomatis agar pengenalan jenis anggrek dapat dilakukan dengan lebih praktis dan efisien. Dalam penelitian ini, dikembangkan sistem klasifikasi citra tanaman anggrek berbasis *deep learning* dengan menggunakan arsitektur *MobileNetV2*. Dataset yang digunakan sebanyak 2.500 citra yang diklasifikasikan ke dalam lima kategori, yakni *Cattleya*, *Dendrobium*, *Oncidium*, *Phalaenopsis*, dan *Vanda*. Pelatihan model dilakukan melalui beberapa variasi pengaturan hyperparameter, seperti *batch size* yaitu 16 dan 32, serta jumlah *epoch* sebesar 25 dan 50, dengan nilai *learning rate* ditetapkan sebesar 0,001. Sementara itu, evaluasi model dilakukan menggunakan *confusion matrix* dengan metrik akurasi, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa kinerja optimal dicapai pada penggunaan *batch size* 32 dan *epoch* 50 dengan nilai akurasi, *precision*, recall, dan F1-score mencapai 99,60%. Temuan ini menegaskan bahwa variasi *hyperparameter* berpengaruh terhadap kinerja model dan *MobileNetV2* mampu memberikan performa klasifikasi yang tinggi dan stabil. Penelitian ini berkontribusi dalam memberikan metode klasifikasi citra tanaman anggrek yang efektif serta menunjukkan bahwa pemilihan *hyperparameter* yang tepat dapat meningkatkan kinerja model secara signifikan.

Kata Kunci: Anggrek, Klasifikasi Citra, *Deep Learning MobileNetV2*, *Hyperparameter*.

1. PENDAHULUAN

Tanaman Anggrek atau yang dikenal dengan orchidaceae merupakan jenis tanaman hias yang

memiliki berbagai macam bentuk tanaman, warna, dan ukuran bunga dengan ciri-ciri yang unik. Keunikan dari bunga anggrek terletak pada

bentuk dan warna bibir atau labellumnya yang membedakan tanaman anggrek dengan tanaman lain [1]. Terdapat beberapa jenis tanaman anggrek yang sangat populer di Indonesia, seperti dendrobium, cattleya, phalaenopsis, dan vanda. Di Indonesia, diperkirakan jumlah spesies tanaman anggrek yang mencapai 5.000 hingga 6.000 jenis yang tumbuh di berbagai wilayah, seperti Kalimantan, Jawa, dan Papua [2].

Tanaman anggrek termasuk jenis tanaman hias yang sangat digemari dan banyak dibudidayakan oleh masyarakat, khususnya di Indonesia. Setiap jenis tanaman ini mempunyai cara budidaya yang berbeda tergantung pada kebutuhan khusus dari setiap jenis tanaman anggrek. Bagi pembudidaya baru, penguasaan informasi terkait jenis-jenis anggrek yang akan dikembangkan menjadi hal yang sangat penting, sehingga proses budidaya dapat dilakukan secara tepat sesuai dengan kebutuhan tanaman. Namun, banyak pembudidaya baru yang mengalami kesulitan dalam mengoptimalkan budidaya tanaman anggrek karena keterbatasan pengetahuan yang dimiliki dalam mengenali jenis tanaman anggrek.

Kesulitan dalam mengenali dan menentukan jenis-jenis tanaman anggrek menjadi masalah utama yang muncul di sebagian kalangan masyarakat. Kesamaan pada bentuk daun, warna dan ukuran bunga yang dimiliki oleh beberapa jenis tanaman anggrek menjadi penyebab dari masalah ini. Bahkan, banyak masyarakat beranggapan bahwa spesies anggrek yang memiliki kemiripan bentuk termasuk dalam jenis yang sama [3]. Keadaan ini dapat menyebabkan kebingungan dan kesalahan dalam menentukan jenis tanaman anggrek, yang pada akhirnya akan berdampak pada perawatan tanaman tersebut. Oleh sebab itu, klasifikasi jenis anggrek memerlukan bantuan teknologi, khususnya pengolahan citra digital melalui metode *deep learning* berupa CNN dengan arsitektur *MobileNetV2*.

Deep learning adalah salah satu cabang dari *Artificial Intelligence* (AI) yang berfungsi mendukung proses klasifikasi citra. Metode ini dapat meningkatkan kinerja komputasi dan akurasi dengan menambah jumlah lapisan pada jaringan [4]. Selain itu, *deep learning* telah diterapkan secara luas pada berbagai aplikasi kecerdasan buatan, termasuk deteksi objek, pengenalan suara, dan terjemahan bahasa. Dalam penerapan metode ini, CNN kerap dimanfaatkan untuk mendeteksi serta mengelompokkan citra yang memiliki pola dan karakteristik yang kompleks.

Convolutional Neural Network (CNN) merupakan sebuah metode *deep learning* yang dirancang untuk menangani data berstruktur grid atau dua dimensi, misalnya gambar maupun sinyal audio. CNN termasuk jenis jaringan saraf tiruan yang secara khusus dikembangkan untuk memproses data citra [5]. CNN dapat menghasilkan tingkat akurasi yang tinggi karena proses konvolusi pada CNN mampu mengekstraksi dan mengenali fitur-fitur penting yang terdapat dalam sebuah citra.

MobileNetV2 adalah arsitektur *Convolutional Neural Network* (CNN) yang dirancang untuk menghasilkan performa klasifikasi yang baik dengan kompleksitas komputasi yang lebih ringan. Model ini memanfaatkan 32 filter pada tahap awal serta 19 lapisan *bottleneck* dengan pendekatan *inverted residual* dan *linear bottleneck*, sehingga proses pengambilan fitur menjadi lebih efisien tanpa menurunkan tingkat akurasi [6]. Arsitektur *MobileNetV2* memiliki ukuran yang kecil, hanya sekitar 14 MB, namun tetap memberikan performa yang sangat baik.

Dalam sejumlah penelitian, *Convolutional Neural Network* (CNN) kerap digunakan untuk tugas klasifikasi citra, seperti yang dilakukan oleh [7] dengan judul "Klasifikasi Genus Tanaman Anggrek Menggunakan *Convolutional Neural Network* (CNN) Dengan Menggunakan Arsitektur VGG 16" mendapatkan performa akurasi sebesar 99,42% dengan mengklasifikasikan tanaman anggrek kedalam lima kelas. Penelitian tentang klasifikasi citra dengan metode CNN juga dilakukan oleh [8] dengan judul "Klasifikasi Lima Jenis Tanaman Herbal Berbasis *Convolutional Neural Network* Menggunakan Arsitektur *MobileNetV2*" mendapatkan nilai akurasi sebesar 94% dengan menggunakan Lima jenis tanaman herbal berdasarkan citra daun, yaitu daun sirih, daun pepaya, daun jambu biji, lidah buaya, dan daun kemangi. Penelitian selanjutnya juga dilakukan oleh [9] yang berjudul "Klasifikasi Spesies Jamur Menggunakan *Convolutional Neural Network* dengan Arsitektur *MobileNetV2*" menggunakan 10 spesies jamur (5 aman dan 5 beracun) memperoleh akurasi sebesar 95,33%, dengan rata-rata nilai *precision*, *recall*, dan *F1-score* masing-masing mencapai 95%. Melalui penelitian ini metode CNN dengan arsitektur *MobileNetV2* diterapkan untuk mengoptimalkan kinerja klasifikasi dan meningkatkan ketepatan pengenalan citra tanaman.

Meskipun demikian, penelitian-penelitian tersebut belum secara khusus membahas pengaruh variasi *hyperparameter* terhadap performa model *MobileNetV2* dalam klasifikasi citra tanaman anggrek. Selain itu, penyesuaian

parameter pelatihan seperti *batch size* dan *epoch* juga belum dievaluasi secara menyeluruh dalam hal klasifikasi jenis tanaman anggrek. Keterbatasan tersebut menunjukkan adanya kesenjangan penelitian, sehingga belum diperoleh konfigurasi optimal yang mampu menghasilkan kinerja model secara maksimal.

Dari uraian latar belakang tersebut, penelitian ini bertujuan mengklasifikasikan lima jenis anggrek *Dendrobium*, *Cattleya*, *Phalaenopsis*, *Oncidium*, dan *Vanda* melalui metode CNN dengan arsitektur *MobileNetV2*. Arsitektur ini dipilih, karena mampu memberikan hasil klasifikasi yang tinggi dengan beban komputasi dan kompleksitas model yang relatif rendah. *MobileNetV2* menggunakan konsep *depthwise separable convolution* dan *inverted residual* yang membuat proses komputasi menjadi lebih efisien tanpa mengurangi akurasi secara signifikan. Kontribusi utama penelitian ini adalah mengevaluasi performa *MobileNetV2* pada klasifikasi citra anggrek dengan variasi *hyperparameter* serta menentukan konfigurasi optimal yang dapat meningkatkan akurasi dan stabilitas model. Dengan demikian, penelitian ini diharapkan dapat membantu proses identifikasi jenis anggrek secara otomatis, cepat, dan lebih akurat.

2. TINJAUAN PUSTAKA

2.1 Jenis Tanaman Anggrek

Orchidaceae, yang lebih dikenal sebagai anggrek, merupakan tanaman hias yang banyak digemari karena bunganya memiliki bentuk yang indah dan unik, sehingga bunga menjadi bagian paling penting pada tanaman anggrek sekaligus penanda utama yang membedakannya. [10]. Tanaman anggrek ini tersebar sekitar 26.000 spesies di seluruh dunia, dan ditemukan sekitar 5.000- 6.000 spesies di Indonesia [11]. Keanekaragaman bentuk, warna, serta ukuran bunga pada tanaman anggrek disertai ciri-ciri unik menjadikan tanaman ini berbeda dibandingkan dengan tanaman lainnya. Sebagai komoditas hortikultura bernilai ekonomi tinggi, tanaman anggrek banyak dibudidayakan oleh berbagai kalangan. Beberapa jenis anggrek yang paling sering dibudidayakan di antaranya adalah *Cattleya*, *Dendrobium*, *Phalaenopsis*, *Vanda*, dan *Oncidium*. *Cattleya* memiliki daun berbentuk jorong meruncing atau memanjang dengan tekstur tebal dan permukaan licin, *Dendrobium* berdaun panjang dan relatif tipis sehingga tampak ramping, *Phalaenopsis* memiliki daun lebar berukuran sekitar 5–10 cm yang tersusun rapat dan saling berhadapan, *Vanda* berdaun tumbuh berselang-seling dengan batang tegak


lurus ke atas, sedangkan *Oncidium* memiliki daun berbentuk pita (memanjang), tipis hingga agak tebal, dan kaku.

2.2 Deep Learning

Deep learning adalah bagian dari *machine learning* yang memanfaatkan jaringan saraf berlapis untuk mengolah data. Metode ini mengandalkan jaringan saraf tiruan dengan sejumlah *hidden layer* yang secara bertahap mampu mengekstraksi serta mempelajari fitur-fitur penting melalui proses pemrosesan bertingkat [12]. Keunggulan metode ini terletak pada kemampuannya dalam mengelola data berukuran besar. Selain itu, model *deep learning* juga dapat meningkatkan efisiensi dan kemudahan dalam berbagai tugas kecerdasan buatan, seperti deteksi objek, pengenalan suara, penerjemahan bahasa, serta pengenalan berbagai pola, termasuk pola grafis dan tulisan tangan. Algoritma ini telah melalui proses pelatihan menggunakan beragam data, sehingga mampu menghasilkan prediksi yang akurat ketika memproses input baru [13].

2.3 Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) merupakan algoritma *deep learning* yang dikembangkan dari *Multilayer Perceptron* (MLP) dan mampu memproses kumpulan data berukuran besar dalam format dua dimensi, seperti citra maupun sinyal audio [14]. Algoritma CNN dapat digunakan dalam menyelesaikan berbagai permasalahan terkait citra seperti klasifikasi. Algoritma ini memiliki kemampuan untuk mengidentifikasi fitur penting melalui proses pembelajaran, ekstraksi, dan representasi fitur dari berbagai jenis data, seperti citra, video, dan teks. Pada umumnya, CNN tersusun atas dua komponen utama, yaitu *feature extraction layer* dan *classification layer*. Bagian *feature extraction layer* terdiri dari *convolutional layer*, *pooling layer* dan *ReLU layer* [15]. Sedangkan *classification layer* meliputi *Fully Connected Layer*, *loss layer* dan *dropout*.



Gambar 1. Struktur CNN [16]

2.4 MobileNetV2

MobileNetV2 merupakan arsitektur Convolutional Neural Network (CNN) yang dikembangkan untuk model klasifikasi gambar berkinerja tinggi dan efisien, terutama pada perangkat komputasi rendah seperti smartphone [17]. Dengan menerapkan teknik *depthwise separable convolution*, arsitektur ini dapat mengurangi jumlah parameter dan biaya komputasi, sehingga menciptakan model yang lebih hemat sumber daya tanpa mengorbankan tingkat akurasi [18]. Teknik ini membagi konvolusi menjadi dua langkah yaitu *depthwise convolution* yang mengekstrak fitur dari setiap channel secara independen, serta *pointwise convolution* (1×1) untuk mengombinasikan output ekstraksi tersebut. Selain itu, MobileNetV2 memperkenalkan konsep *inverted residual block* dan *linear bottleneck*, yaitu struktur yang memperluas jumlah channel fitur pada tahap awal menggunakan konvolusi 1×1, kemudian memprosesnya melalui *depthwise convolution*, dan akhirnya memproyeksikan kembali fitur ke dimensi yang lebih sempit secara linear [19].



Gambar 2. Struktur MobileNetV2 [20]

2.5 Confusion Matrix

Confusion Matrix adalah suatu metode yang banyak digunakan untuk mengukur performa model klasifikasi. Teknik ini disajikan dalam bentuk tabel berukuran $N \times N$ yang menampilkan jumlah prediksi benar serta kesalahan. Melalui *confusion matrix*, jumlah data yang diklasifikasikan secara tepat maupun keliru pada setiap kelas dapat diketahui dan disajikan secara terstruktur dalam bentuk tabel [21]. Matriks ini mencakup empat elemen pokok, yaitu *True Positive* (TP) untuk prediksi positif benar, *True Negative* (TN) untuk prediksi negatif benar, *False Positive* (FP) sebagai kesalahan tipe I (negatif salah diprediksi positif), dan *False Negative* (FN) sebagai kesalahan tipe II (positif salah diprediksi negatif). *Confusion Matrix* menggunakan beberapa metrik evaluasi untuk menganalisis

kinerja model klasifikasi secara lebih rinci, yaitu akurasi, presisi (*precision*), recall, dan F1-score [22]. Akurasi merepresentasikan proporsi total prediksi yang benar, presisi menunjukkan ketepatan prediksi pada kelas positif, *recall* menggambarkan sensitivitas model dalam mengidentifikasi data positif, sementara *F1-score* berfungsi sebagai rata-rata harmonik antara presisi dan *recall*. Keempat metrik tersebut dapat dihitung menggunakan rumus.

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

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


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

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall}$$

3. METODOLOGI PENELITIAN

3.1 Skema Alur Penelitian

Penelitian ini terdiri dari lima tahapan utama yang dilakukan secara sistematis, yaitu pengumpulan data, data preprocessing, perancangan model, proses pelatihan, dan evaluasi model, sebagaimana ditunjukkan pada Gambar 3.



Gambar 3. Tahapan Penelitian

3.2 Pengumpulan Data

Dalam penelitian ini, dataset bersumber dari platform Kaggle bernama "Orchid Genus". Dataset tersebut dipilih karena menyediakan citra tanaman anggrek dengan variasi visual yang tinggi, baik berupa gambar dengan latar belakang (*background*) asli maupun tanpa latar belakang, sehingga dapat merepresentasikan kondisi nyata dalam proses klasifikasi citra. Dataset ini terdiri dari 2.500 citra berformat .jpg yang mencakup lima kelas genus anggrek. Pemilihan dataset ini didasarkan pada kebutuhan model untuk mengenali perbedaan karakteristik visual antar genus anggrek yang memiliki kemiripan

kemiripan morfologis, seperti bentuk daun, sehingga proses klasifikasi menjadi lebih kompleks dan relevan.

3.3 Data Preprocessing

Pada tahap data preprocessing, seluruh citra terlebih dahulu dilakukan proses pembersihan untuk memastikan tidak terdapat gambar yang rusak atau duplikat. Proses ini penting dilakukan untuk menjaga kualitas dataset sehingga model dapat belajar dari data yang valid. Dataset kemudian dibagi menjadi dua yakni 80% untuk pelatihan dan 20% untuk pengujian. Data pelatihan dipakai untuk membangun kemampuan model dalam mempelajari karakteristik data, sedangkan subset pengujian digunakan untuk menilai performa model menggunakan data yang belum pernah digunakan saat pelatihan [23]. Setelah pembagian data, seluruh gambar *resize* menjadi 224×224 piksel. Ukuran ini dipilih karena merupakan standar input yang umum digunakan pada arsitektur *Convolutional Neural Network* (CNN), seperti *MobileNetV2*. Tahap berikutnya adalah melakukan augmentasi pada data pelatihan. Teknik ini digunakan untuk menambah keragaman dan jumlah data melalui modifikasi pada citra yang sudah ada tanpa perlu mengumpulkan data baru dalam jumlah besar [24]. Dalam penelitian ini, augmentasi data diterapkan melalui teknik seperti rotasi dan *horizontal flip* untuk menambah keragaman gambar, sehingga model mampu mendeteksi objek dari berbagai sudut dan orientasi.

3.4 Perancangan Model MobileNetV2

Penelitian ini menggunakan arsitektur *MobileNetV2* sebagai model dalam proses klasifikasi citra genus anggrek. Pemilihan arsitektur ini didasarkan pada kemampuannya yang efisien dalam melakukan ekstraksi fitur dengan jumlah parameter yang relatif lebih kecil. Hal ini menjadikan *MobileNetV2* lebih ringan dan cepat dalam proses pelatihan, namun tetap memiliki performa yang baik dalam tugas klasifikasi citra. Pada penelitian ini, bagian ekstraksi fitur pada *MobileNetV2* dimanfaatkan untuk mengenali karakteristik visual pada citra, sedangkan lapisan klasifikasi bawaan tidak digunakan. Sebagai penggantinya, ditambahkan beberapa lapisan baru yang disesuaikan dengan kebutuhan penelitian. Fitur yang dihasilkan kemudian diringkas menggunakan *Global Average Pooling* untuk mengurangi dimensi data

sebelum masuk ke tahap klasifikasi. Selanjutnya, fitur tersebut diteruskan ke lapisan Dense untuk mempelajari pola yang lebih spesifik pada dataset. Pada lapisan akhir, digunakan fungsi aktivasi Softmax dengan 5 neuron output yang disesuaikan dengan jumlah kelas pada dataset. Fungsi Softmax digunakan untuk menghasilkan probabilitas tiap kelas sehingga model menentukan kelas dengan nilai tertinggi sebagai hasil prediksi akhir.

3.4 Pelatihan Model

Proses pelatihan dilakukan untuk mengetahui konfigurasi *hyperparameter* yang mampu menghasilkan performa terbaik dalam klasifikasi citra anggrek. Pada tahap ini, model dilatih menggunakan *optimizer Adam* (*learning rate* 0,001) serta fungsi *loss categorical crossentropy* yang ideal untuk tugas klasifikasi multikelas. Penggunaan *Optimizer Adam* dipilih karena memiliki kemampuan adaptif dalam memperbarui bobot secara efisien, sedangkan pemilihan *learning rate* 0,001 digunakan karena memberikan keseimbangan antara kecepatan konvergensi dan stabilitas proses pelatihan. Untuk menganalisis pengaruh *hyperparameter* terhadap kinerja model, diterapkan empat kombinasi parameter yang terdiri dari variasi *batch size* 16 dan 32 serta *epoch* 25 dan 50. Variasi *batch size* ini digunakan untuk membandingkan pengaruh jumlah sampel dalam satu kali pembaruan bobot, di mana *batch size* 16 memungkinkan pembaruan lebih sering sehingga model belajar lebih detail, sedangkan *batch size* 32 memberikan pelatihan yang lebih stabil dan efisien. Sementara itu, variasi *epoch* 25 dan 50 digunakan untuk membandingkan durasi pelatihan, di mana *epoch* 25 membantu meminimalkan risiko *overfitting*, sementara penggunaan 50 *epoch* memungkinkan model mempelajari pola data secara lebih optimal. Seluruh kombinasi *hyperparameter* yang digunakan dalam penelitian ini disajikan pada Tabel I.

TABEL I. SKENARIO HYPERPARAMETER

Skenario	Learning Rate	Batch Size	Epoch
1	0.001	16	25
2	0.001	16	50
3	0.001	32	25
4	0.001	32	50

3.5 Evaluasi Model

Penilaian kinerja model dalam penelitian ini dilakukan melalui penggunaan *confusion matrix* untuk mengidentifikasi hubungan antara prediksi yang dihasilkan model dan label sebenarnya pada data pengujian. Penggunaan *confusion matrix* dipilih karena mampu memberikan gambaran yang lebih rinci mengenai performa klasifikasi, termasuk jumlah prediksi benar dan salah pada setiap kelas, sehingga tidak hanya bergantung pada satu nilai akurasi saja. Evaluasi ini menggunakan data uji yang tidak termasuk dalam proses pelatihan, sehingga hasil yang diperoleh mampu merepresentasikan kemampuan model dalam mengklasifikasikan data yang belum pernah dilihat sebelumnya. Dari *confusion matrix*, kemudian dihitung metrik evaluasi model seperti akurasi, precision, recall, dan F1-score dihitung untuk mengukur performa klasifikasi. Langkah ini bertujuan mengevaluasi kemampuan model dalam mengklasifikasikan data secara tepat [25].

4. HASIL DAN PEMBAHASAN

4.1 Dataset

Dataset dalam penelitian ini, terdiri dari 2.500 citra anggrek yang dikelompokkan menjadi lima kategori, yakni Dendrobium, Phalaenopsis, Vanda, Oncidium, dan Cattleya. Masing-masing kelas terdiri dari 500 citra yang terbagi menjadi 250 citra anggrek dengan latar belakang dan 250 citra tanpa latar belakang, Komposisi dataset yang seimbang antar kelas bertujuan untuk menghindari bias model terhadap kelas tertentu, sehingga model memiliki peluang yang sama dalam mempelajari setiap kategori. Variasi latar belakang juga memberikan tantangan tambahan bagi model dalam melakukan ekstraksi fitur terhadap kondisi lingkungan berbeda. Berikut merupakan contoh citra dari setiap kelas yang ditampilkan pada Gambar 4.



Gambar 4. Sampel Dataset Lima Kelas Anggrek

4.2 Preprocessing Data


Pada tahap ini, seluruh citra sebanyak 2.500 gambar terlebih dahulu dilakukan proses pembersihan data. Selanjutnya, dataset dibagi

menjadi 2.000 citra sebagai data pelatihan dan 500 citra sebagai data pengujian, dengan distribusi setiap kelas masing-masing 400 citra untuk *training* dan 100 citra untuk *testing*. Kemudian, seluruh citra dilakukan proses *resizing* menjadi ukuran 224×224 piksel. Pada data pelatihan dilakukan dua jenis augmentasi, sehingga data pelatihan meningkat menjadi 6.000 citra dan masing-masing kelas memiliki 1.200 citra *training*. Jumlah data *training* setelah augmentasi ditampilkan pada Gambar 5.

Kelas	Data Training Awal	Data Augmentasi	Data Setelah Digabung
Dendrobium	400	800	1.200
Phalaenopsis	400	800	1.200
Vanda	400	800	1.200
Oncidium	400	800	1.200
Cattleya	400	800	1.200
Jumlah Data Training			6.000

Gambar 5. Jumlah Data Training

Hasil augmentasi data *training* ditunjukkan pada gambar 5, yang memperlihatkan penerapan teknik rotasi dan horizontal flip pada citra anggrek. Proses augmentasi ini bertujuan untuk menambah keragaman data dan mensimulasikan kondisi nyata seperti perbedaan sudut pengambilan gambar, sehingga model lebih optimal dalam mengenali objek pada berbagai kondisi dan orientasi.

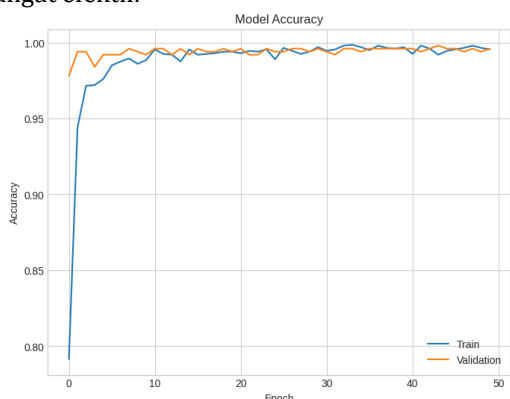


Gambar 6. Contoh Hasil Augmentasi

4.3 Pelatihan model


Pada penelitian ini dilakukan empat skenario pengujian untuk menganalisis pengaruh variasi hyperparameter berupa batch size dan *epoch* terhadap kinerja model. Pengujian ini bertujuan untuk memperoleh konfigurasi yang paling optimal dalam proses klasifikasi citra anggrek, sehingga tidak hanya menghasilkan akurasi tinggi tetapi juga model yang stabil dan memiliki kemampuan generalisasi yang baik. Hasil pengujian menunjukkan bahwa setiap kombinasi parameter memberikan pengaruh terhadap performa model. Pada skenario dengan *batch size* 32 dan *epoch* 50, model menghasilkan performa terbaik dengan nilai akurasi, presisi, recall, dan

F1-score sebesar 99,60%. Tingginya nilai tersebut menunjukkan bahwa model mampu mempelajari pola fitur citra anggrek secara sangat efektif.



Gambar 7. Kurva Akurasi dengan Batch Size 32 Epoch 50

Berdasarkan kurva akurasi pada Gambar 7, terlihat bahwa proses pembelajaran model berjalan secara bertahap. Pada awal pelatihan, akurasi *training* masih rendah karena model masih beradaptasi dalam mengenali pola data. Namun, peningkatan yang signifikan pada beberapa *epoch* awal menunjukkan bahwa model cepat mampu mengekstraksi fitur penting dari dataset. Stabilitas akurasi *training* dan validasi setelah sekitar *epoch* ke-10 menunjukkan bahwa model telah mencapai kondisi konvergen. Kedekatan kedua kurva juga mengindikasikan bahwa model tidak mengalami *overfitting*, karena tidak terdapat kesenjangan signifikan antara data pelatihan dan validasi.




Gambar 8. Kurva Loss dengan Batch Size 32 Epoch 50

Berdasarkan gambar 8, terlihat bahwa nilai loss yang awalnya tinggi mengalami penurunan tajam pada awal *epoch*, kemudian menurun secara bertahap hingga stabil pada nilai yang

sangat rendah. Pola ini menunjukkan bahwa kesalahan prediksi model semakin kecil seiring bertambahnya proses pelatihan. Konsistensi loss pada data *training* dan validasi juga memperkuat bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru. Selain itu, stabilitas nilai loss pada *epoch* akhir menunjukkan bahwa model telah mencapai kondisi konvergen dengan optimal. Hal ini mengindikasikan bahwa proses pembelajaran berjalan efektif tanpa adanya indikasi *overfitting* yang signifikan.


Pada skenario *batch size* 16 dengan jumlah *epoch* sebanyak 50, model memperoleh akurasi sebesar 99,40%, presisi 99,41%, recall 99,40%, dan F1-score 99,40%. Hasil ini menunjukkan bahwa model memiliki performa klasifikasi yang sangat tinggi dan mampu mengenali pola citra anggrek dengan baik pada seluruh kelas. Konsistensi nilai pada setiap metrik evaluasi juga mengindikasikan bahwa model tidak hanya akurat, tetapi juga stabil dalam melakukan prediksi pada data uji. Selain itu, tingginya nilai recall menunjukkan bahwa model mampu mendeteksi sebagian besar data pada setiap kelas dengan baik tanpa banyak data yang terlewat. Hal ini memperkuat bahwa model memiliki kemampuan generalisasi yang baik terhadap variasi data uji.



Gambar 9. Kurva Akurasi dengan Batch Size 16 Epoch 50

Berdasarkan hasil kurva akurasi pada Gambar 9, terlihat bahwa pada *epoch* pertama akurasi *training* masih berada pada nilai yang relatif rendah, kemudian meningkat secara signifikan pada beberapa *epoch* awal. Akurasi validasi sejak awal sudah menunjukkan nilai yang tinggi dan cenderung stabil di sekitar nilai maksimum. Pada *epoch* ke-10, urva akurasi

training dan validasi mulai menunjukkan pola yang stabil dan saling berdekatan hingga akhir pelatihan. Kondisi ini menunjukkan bahwa model telah mencapai titik konvergensi dan tidak mengalami *overfitting*, karena tidak terdapat perbedaan yang signifikan antara performa data *training* dan validasi.



Gambar 10. Kurva Loss dengan *Batch Size 16 Epoch 50*.

Hasil kurva loss Gambar 10 memperlihatkan pada *epoch* pertama nilai loss cukup tinggi kemudian menurun secara signifikan pada beberapa *epoch* awal. Penurunan ini menunjukkan bahwa model berhasil mengurangi kesalahan prediksi secara bertahap seiring proses pembelajaran. Loss validasi yang ikut menurun dan mengikuti pola yang sama memperkuat bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang tidak digunakan dalam pelatihan. Pada *epoch* ke-10 hingga akhir pelatihan, baik loss *training* maupun validasi cenderung stabil dan berada pada rentang nilai yang rendah. Hal ini menunjukkan bahwa kesalahan prediksi model semakin kecil dan proses pembelajaran telah mencapai kondisi optimal, sehingga model mampu menghasilkan prediksi yang konsisten dan andal.

Skenario	Learning Rate	Batch Size	Epoch	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
1	0.001	16	25	99.20%	99.21%	99.20%	99.20%
2	0.001	16	50	99.40%	99.41%	99.40%	99.40%
3	0.001	32	25	99.40%	99.41%	99.40%	99.40%
4	0.001	32	50	99.60%	99.60%	99.60%	99.60%

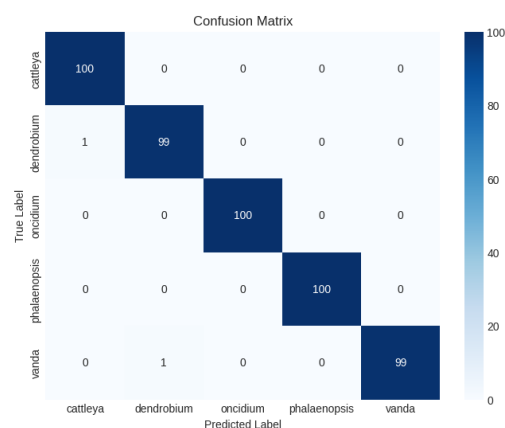
Gambar 11. Hasil Setiap Skenario Pengujian.

Berdasarkan hasil pengujian pada empat skenario yang ditampilkan pada Gambar 11, seluruh konfigurasi parameter menunjukkan performa yang sangat baik dengan nilai evaluasi yang tinggi. Secara umum, terlihat bahwa peningkatan jumlah *epoch* dari 25 menjadi 50

memberikan dampak positif terhadap peningkatan nilai akurasi, presisi, recall, dan F1-score pada model, karena model memiliki waktu pembelajaran yang lebih cukup untuk menangkap karakteristik fitur citra secara optimal. Hasil pengujian juga menunjukkan bahwa kombinasi *batch size 32* dan *epoch 50* merupakan konfigurasi terbaik, dengan nilai akurasi, precision, recall, dan F1-score masing-masing sebesar 99,60%. Hasil ini mengindikasikan bahwa kombinasi tersebut mampu memberikan keseimbangan terbaik antara stabilitas proses pelatihan dan kemampuan generalisasi model. Kombinasi ini terbukti paling efektif dalam mengidentifikasi pola gambar tanaman anggrek karena mampu menghasilkan performa yang konsisten, stabil, serta minim kesalahan klasifikasi dibandingkan skenario lainnya.

4.4 Evaluasi Model

Dalam penelitian ini, confusion matrix dimanfaatkan untuk mengukur ketepatan performa model. Data pengujian terdiri dari 100 citra pada setiap kelas, sehingga hasil prediksi model dapat dibandingkan dengan label sebenarnya untuk mengidentifikasi jumlah prediksi yang tepat maupun yang salah. Melalui metode ini, dapat diketahui distribusi kesalahan klasifikasi pada setiap kelas.



Gambar 12. Hasil *Confusion Matrix* dengan *Batch Size 32 Epoch 50*

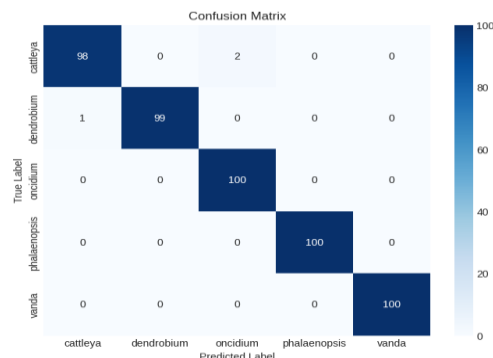
Dari hasil pada Gambar 12, terlihat bahwa mayoritas data uji berhasil diklasifikasikan dengan tepat oleh model. Kelas *Cattleya*, *Oncidium*, dan *Phalaenopsis* seluruhnya diprediksi dengan benar tanpa adanya kesalahan klasifikasi. Hal ini menunjukkan bahwa model

memiliki kemampuan yang sangat baik dalam mengenali karakteristik visual yang jelas dan khas pada ketiga kelas tersebut. Tingginya tingkat keberhasilan pada kelas-kelas ini mengindikasikan bahwa fitur yang dipelajari model sudah cukup representatif dalam membedakan pola visual antar kelas. Namun demikian, pada kelas Dendrobium terdapat satu data yang salah diprediksi sebagai Cattleya, sedangkan pada kelas Vanda terdapat satu data yang diprediksi sebagai Dendrobium. Meskipun jumlah kesalahan tergolong sangat kecil, hal ini tetap menunjukkan adanya kemiripan fitur visual antar kelas tertentu yang dapat mempengaruhi hasil klasifikasi. Kesalahan klasifikasi tersebut dapat dilihat lebih jelas pada Gambar 13 yang menampilkan contoh citra yang mengalami kesalahan klasifikasi oleh model.



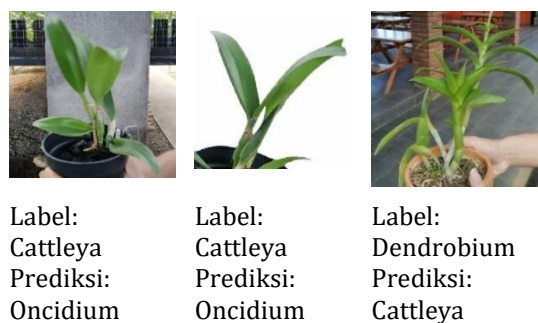
Gambar 13. Contoh Kesalahan Klasifikasikan pada *Batch Size 32 Epoch 50*

Berdasarkan Gambar 13, dapat dilihat bahwa beberapa citra mengalami kesalahan klasifikasi oleh model. Kesalahan klasifikasi tersebut muncul akibat adanya kesamaan karakteristik visual antar kelas, khususnya pada bentuk daun yang memiliki struktur serta pola yang hampir mirip, sehingga menyulitkan model untuk membedakan tiap kelas dengan tepat. Dalam beberapa kondisi, fitur yang diekstraksi memiliki pola yang hampir serupa sehingga model cenderung menghasilkan prediksi yang keliru pada kelas yang memiliki kemiripan visual tinggi. Namun demikian, jumlah kesalahan yang terjadi relatif sedikit jika dibandingkan dengan keseluruhan data uji, yang menunjukkan bahwa model tetap mampu memberikan hasil klasifikasi yang sangat baik pada mayoritas citra.



Gambar 14. Hasil *Confusion Matrix* dengan *Batch Size 16 Epoch 50*

Berdasarkan Gambar 14, terlihat bahwa model berhasil mengklasifikasikan sebagian besar data uji secara tepat pada setiap kelas. Kelas Oncidium, Phalaenopsis, dan Vanda menunjukkan hasil yang sepenuhnya benar tanpa adanya kesalahan prediksi. Hal ini mengindikasikan bahwa model mampu mengenali karakteristik visual yang khas dan konsisten pada ketiga kelas tersebut, sehingga proses ekstraksi fitur berjalan dengan sangat baik. Namun, pada kelas Cattleya terdapat dua citra yang diprediksi sebagai Oncidium, sedangkan pada kelas Dendrobium terdapat satu citra yang diprediksi sebagai Cattleya. Meskipun jumlah kesalahan tergolong sangat kecil, kondisi ini menunjukkan adanya kemiripan fitur visual antar kelas tertentu yang dapat memengaruhi keputusan klasifikasi model. Hal tersebut juga mengindikasikan bahwa model masih memiliki keterbatasan dalam membedakan fitur yang bersifat halus (*fine-grained features*) antar kelas anggrek. Secara keseluruhan, kesalahan yang terjadi relatif sedikit dibandingkan dengan total data uji, sehingga performa model tetap dapat dikategorikan sangat baik. Untuk memberikan gambaran yang lebih jelas mengenai kesalahan tersebut, contoh citra yang mengalami kesalahan klasifikasi ditampilkan pada Gambar 15.



Gambar 15. Contoh Kesalahan Klasifikasikan pada *Batch Size 16 Epoch 50*

Berdasarkan Gambar 15, contoh kesalahan klasifikasi memperlihatkan bahwa citra yang salah diprediksi umumnya memiliki kemiripan pada bentuk daun. Kemiripan ini menyebabkan model kesulitan dalam membedakan kelas secara akurat, terutama ketika perbedaan antar kelas tidak terlalu signifikan secara visual. Dalam kasus ini, model cenderung menangkap fitur dominan yang mirip dengan kelas lain sehingga menghasilkan prediksi yang kurang tepat. Selain itu, faktor variasi citra seperti sudut pengambilan gambar juga dapat turut mempengaruhi hasil klasifikasi, meskipun telah dilakukan augmentasi pada tahap preprocessing. Meskipun demikian, jumlah kesalahan yang terjadi tetap relatif kecil dibandingkan keseluruhan data uji, sehingga secara keseluruhan model dapat dikatakan memiliki performa yang sangat baik, stabil, dan mampu memberikan hasil klasifikasi yang andal pada berbagai kelas anggrek.

5. Kesimpulan dan Saran

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penggunaan arsitektur *MobileNetV2* pada klasifikasi citra genus anggrek berhasil mencapai tujuan penelitian, yaitu membangun model klasifikasi yang akurat dan efisien dalam mengenali lima kelas anggrek. Model yang dikembangkan mampu memanfaatkan fitur visual citra secara optimal melalui proses transfer learning, sehingga menghasilkan performa klasifikasi yang tinggi. Hasil pengujian pada empat skenario menunjukkan bahwa variasi hyperparameter berpengaruh terhadap kinerja model, di mana konfigurasi terbaik diperoleh pada *batch size* 32 dan *epoch* 50 dengan akurasi sebesar 99,60%. Hal ini menunjukkan bahwa peningkatan jumlah *epoch* memberikan kesempatan bagi model untuk mempelajari pola data secara lebih optimal, sementara *batch size* yang lebih besar memberikan stabilitas dalam proses pembaruan bobot. Evaluasi menggunakan *confusion matrix* menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik pada seluruh kelas, dengan tingkat kesalahan yang sangat rendah. Meskipun masih terdapat beberapa kesalahan pada kelas tertentu, hal tersebut lebih disebabkan oleh kemiripan fitur visual antar kelas yang memiliki karakteristik hampir serupa. Secara keseluruhan, model menunjukkan kemampuan generalisasi yang baik dan mampu membedakan karakteristik antar kelas secara efektif, sehingga tujuan penelitian telah tercapai dengan baik.

5.2 Saran

Untuk penelitian selanjutnya, disarankan untuk memperluas dan memperkaya dataset dengan variasi kondisi nyata seperti pencahayaan ekstrem, latar belakang yang lebih kompleks, serta perbedaan fase pertumbuhan bunga agar model memiliki kemampuan generalisasi yang lebih baik pada kondisi lapangan. Selain itu, pengembangan metode dapat dilakukan dengan meningkatkan optimasi proses pelatihan melalui penyesuaian *hyperparameter* yang lebih luas serta eksplorasi teknik augmentasi data yang lebih variatif untuk memperkaya karakteristik data latih. Selain itu, penelitian selanjutnya juga disarankan melakukan perbandingan dengan arsitektur deep learning lainnya seperti *ResNet*, *EfficientNet*, atau *DenseNet* guna memperoleh evaluasi yang lebih komprehensif dan memperkuat kontribusi ilmiah dalam bidang klasifikasi citra berbasis *deep learning*.

6. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dan bantuan selama pelaksanaan penelitian ini. Penulis berharap karya ini dapat memberikan manfaat yang luas sekaligus menjadi referensi bagi studi-studi selanjutnya.

Daftar Pustaka:

- [1] A. Faiza Al Farakhi, F. Alif Fiolana, and F. Yamono, "Klasifikasi Bunga Anggrek Bulan Berdasarkan Warna dan Teksturnya Menggunakan Metode JST," *J. Ilm. Sist. Inf.*, vol. 1, no. 3, pp. 25–37, 2022.
- [2] R. P. Putra, "Identifikasi Jenis Tanaman Anggrek Melalui Tekstur Bunga dengan Tapis Gabor dan M-SVM," *JOINTECS (Journal Inf. Technol. Comput. Sci.)*, vol. 6, no. 1, p. 29, 2021, doi: 10.31328/jointecs.v6i1.1746.
- [3] M. Baihaqy, A. T. Wibowo, and D. Q. Utama, "Klasifikasi Tanaman Anggrek jenis Phalaenopsis berdasarkan Citra Labellum Bunga Menggunakan Metode Convolutinal Neural Network (CNN)," *e-Proceeding Eng.*, vol. 9, no. 3, pp. 1942–1951, 2022.
- [4] N. P. K. Dewi, P. H. Suputra, A. A. G. Y. Paramartha, L. J. E. Dewi, P. Varnakovida, and K. Y. E. Aryanto, "River Area Segmentation Using Sentinel-1 SAR Imagery with Deep-Learning Approach," *Geomatics Environ. Eng.*, vol. 19, no. 4, pp. 39–63, 2025, doi: 10.7494/geom.2025.19.4.39.

- [5] D. A. Pusparani, M. W. A. Kesiman, and K. Y. E. Aryanto, "Identification of Little Tuna Species Using Convolutional Neural Networks (CNN) Method and ResNet-50 Architecture," *Indones. J. Artif. Intell. Data Min.*, vol. 8, no. 1, p. 86, 2024, doi: 10.24014/ijaidm.v8i1.31620.
- [6] A. R. Hermanto, A. Aziz, and S. Sudioanto, "Perbandingan Arsitektur MobileNetV2 dan ResNet50 untuk Klasifikasi Jenis Buah Kurma," *J. Sist. dan Teknol. Inf.*, vol. 12, no. 4, pp. 630–637, 2024, doi: 10.26418/justin.v12i4.80358.
- [7] Z. Zulkipli, L. A. S. I. A. Akbar, and B. Kanata, "Klasifikasi Genus Tanaman Anggrek Menggunakan Convolutional Neural Network (CNN) dengan Arsitektur VGG16," *J. Inform. Teknol. dan Sains*, vol. 6, no. 4, pp. 820–829, 2024.
- [8] F. N. Fadillah and T. Informatika, "Klasifikasi Lima Jenis Tanaman Herbal Berbasis Convolutional Neural Network Menggunakan Arsitektur MobileNetV2," vol. 5, pp. 275–280, 2026.
- [9] M. A. Hakiki, N. Rachmat, and K. Kunci-Cnn, "Klasifikasi Spesies Jamur Menggunakan Convolutional Neural Network dengan Arsitektur MobileNetV2," *J. Algoritm.*, vol. 5, no. 3, pp. 274–287, 2025, doi: 10.35957/algoritme.v6i1.11077.
- [10] K. Husodo, C. Lubis, and Z. Rusdi, "Klasifikasi Tanaman Anggrek Menggunakan Convolutional Neural Network Dengan Arsitektur Vgg-19," *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 8, no. 2, pp. 253–258, 2023, doi: 10.51876/simtek.v8i2.214.
- [11] Puspitasari and A. T. Wibowo, "Klasifikasi Bunga Anggrek untuk Genus Grammatophyllum Menggunakan Metode Convolutional Neural Network (CNN)," *e-Proceeding Eng.*, vol. 8, no. 5, pp. 10527–10543, 2021.
- [12] K. A. Tamayasa *et al.*, "Analisis Perbandingan Model Arsitektur MobileNetV2 dan EfficientNetB3 dalam Penyakit Daun Jagung," *J. Inform. dan Tek. Elektro Terap.*, vol. 14, no. 1.
- [13] M. Raihan Rafiiful Allaam and A. Toto Wibowo, "Klasifikasi Genus Tanaman Anggrek Menggunakan Metode Convolutional Neural Network (Cnn)," *e-Proceeding Eng.*, vol. 8, no. 2, pp. 3147–3179, 2021.
- [14] I. Rizki Ramadhani, A. Nilogiri, and Q. A'yun, "Klasifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network Classification Of Plants Based On Leaf Image Using Convolutional Neural Network Method," *J. Smart Teknol.*, vol. 3, no. 3, pp. 2774–1702, 2022.
- [15] A. C. Milano, "Klasifikasi Penyakit Daun Padi Menggunakan Model Deep Learning Efficientnet-B6," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, 2024, doi: 10.23960/jitet.v12i1.3855.
- [16] F. Bozkurt, "A Study on CNN Based Transfer Learning for Recognition of Flower Species," *Eur. J. Sci. Technol.*, no. 32, pp. 883–890, 2022, doi: 10.31590/ejosat.1039632.
- [17] K. Ratna Mutu Manikam, L. Joni Erawati Dewi, K. Yota Ernanda Aryanto, K. Agus Seputra, and P. Varnakovida, "Analisis Hyperparameter Pada Klasifikasi Jenis Tanaman Menggunakan Algoritma Resnet50 Dan Mobilenetv2," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 6, pp. 9921–9928, 2025, doi: 10.36040/jati.v9i6.15832.
- [18] Didi Kurniawan and Dhani Ariatmanto, "Identifikasi Varietas Bibit Durian Menggunakan Mobilenetv2 Berdasarkan Gambar Daun," *J. Inform. dan Rekayasa Elektron.*, vol. 7, no. 2, pp. 231–240, 2024, doi: 10.36595/jire.v7i2.1236.
- [19] N. Nafiyah and T. Dwi Lestari, "Perbandingan Vgg16, Vgg19, Mobilenet Dan Mobilenetv2 Untuk Klasifikasi Beras Berdasarkan Citra," *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 11, no. 1, pp. 1368–1380, 2026, doi: 10.36341/rabit.v11i1.7338.
- [20] S. Arnandito and T. B. Sasongko, "Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks," *J. Appl. Informatics Comput.*, vol. 8, no. 1, pp. 176–185, 2024, doi: 10.30871/jaic.v8i1.7927.
- [21] M. Riyyan and H. Firdaus, "Perbandingan Algoritme Naive Bayes Dan Knn Terhadap Data Penerimaan Beasiswa (Studi Kasus Lembaga Beasiswa Baznas Jabar)," *J. Inform. dan Rekayasa Elektron.*, vol. 5, no. 1, pp. 1–10, 2022, doi: 10.36595/jire.v5i1.547.
- [22] I. Kadek Nicko Ananda, Ni Putu Novita Puspa Dewi, Ni Wayan Marti, and Luh Joni Erawati Dewi, "Klasifikasi Multilabel Pada Gaya Belajar Siswa Sekolah Dasar Menggunakan Algoritma Machine

- Learning," *J. Appl. Comput. Sci. Technol.*, vol. 5, no. 2, pp. 144–154, 2024, doi: 10.52158/jacost.v5i2.940.
- [23] N. Putu, "Klasifikasi Jenis Daun Tumbuhan Herbal Berdasarkan Lontar Usada Taru Pramana Menggunakan CNN," *Techno. Com.*, vol. 23, no. 1, pp. 271–283, 2024.
- [24] P. Prianka Vedanty, M. Windu Antara Kesiman, and I. M. Gede Sunarya, "Pengaruh Data Augmentasi Pada Identifikasi Penyakit Daun Tanaman Obat Menggunakan K-Nearest Neighbor," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 2, pp. 2094–2100, 2025, doi: 10.36040/jati.v9i2.12961.
- [25] A. Setiawan, Z. H. Nst, Z. Khairi, and L. Efrizoni, "Klasifikasi Tingkat Risiko Diabetes Menggunakan Algoritma Random Fores," *J. Inform. dan Rekayasa Elektron.*, vol. 7, no. 2, pp. 263–271, 2024.