

Penerapan Arsitektur CNN EfficientNet-B1 untuk Klasifikasi Tanaman Hias Tropis

Muhammad Fathul Yadi^{*1}, Maura Widyaningsih², Lili Rusdiana³

^{1,2,3}STMIK Palangkaraya, Palangkaraya

e-mail: ^{*1}fathulonta86@gmail.com, ²maura@stmikplk.ac.id, ³fasliiana7@gmail.com

Abstrak

Penelitian ini mengembangkan klasifikasi tanaman hias tropis Indonesia menggunakan CNN EfficientNet-B1 berbasis transfer learning. Dataset Kaggle diproses melalui prapemrosesan, pelatihan, dan pengujian pada tujuh skenario dengan metrik akurasi, presisi, recall, dan F1. Model masih kesulitan membedakan beberapa kelas tanaman dari objek non-tanaman, namun Skenario 1 mencapai akurasi 98% dan F1 97,92% dengan presisi-recall seimbang. Kinerja sangat dipengaruhi kualitas/keimbangan data dan penyetalan hiperparameter, sehingga disarankan augmentasi, penyeimbangan kelas, serta optimasi parameter pelatihan. Metode ini berpotensi untuk sistem identifikasi otomatis yang mendukung hortikultura, konservasi, dan perdagangan tanaman tropis di Indonesia.

Kata kunci— CNN EfficientNet-B1, Deep Learning, Klasifikasi tanaman, Tanaman hias tropis

1. PENDAHULUAN

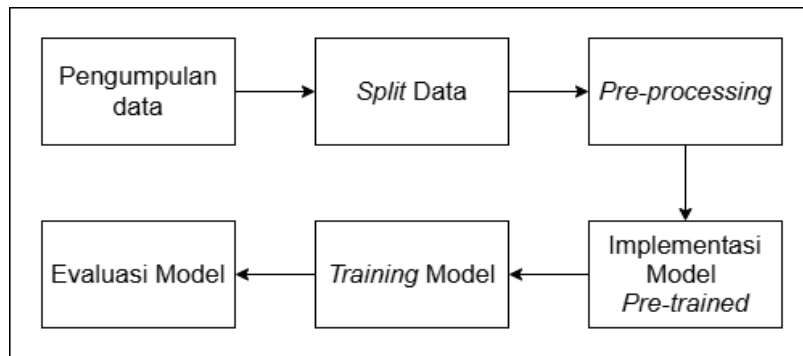
Indonesia memiliki kekayaan tanaman hias yang bernilai estetika, lingkungan, dan ekonomi [1]. Selain memperindah ruang, tanaman hias menyerap polutan, meningkatkan kualitas udara, dan menurunkan stres [2]. Meningkatnya minat publik menuntut identifikasi spesies yang akurat, sementara cara manual lambat dan butuh keahlian, serta terkendala kemiripan morfologi. Pendekatan deep learning berbasis Convolutional Neural Network (CNN) efektif karena mampu mengekstraksi fitur visual penting untuk klasifikasi citra tanaman [3,4,5].

Penelitian terdahulu mendukung pendekatan ini: SVM+GLCM mencapai 75% namun kurang pada pola mirip [2] CNN untuk tanaman hias mencapai akurasi uji 98,75% [6]; transfer learning EfficientNet meningkatkan efisiensi dan akurasi serta potensial real-time [7]; EfficientNet-B1 juga unggul pada pola citra kompleks dengan akurasi 0,98 [8]. Temuan-temuan ini menguatkan dasar penggunaan CNN, khususnya EfficientNet, untuk klasifikasi tanaman hias tropis yang serupa secara visual.

Penelitian ini memilih EfficientNet-B1 karena efisien komputasi dan efektif pada citra berukuran relatif kecil [9][10]. Tujuannya menerapkan model pre-trained dengan penyetalan hiperparameter untuk mengklasifikasikan tanaman hias tropis berdasarkan ciri visual, bentuk daun, bunga, serta pola dan warna [11]. Tahapan mencakup pengumpulan data dari Kaggle, pembagian data, prapemrosesan, dan transfer learning dengan ekstraksi fitur. Kinerja dievaluasi menggunakan confusion matrix serta akurasi, precision, recall, dan F1-score, sehingga diharapkan memberi solusi aplikatif untuk identifikasi tanaman hias tropis sekaligus mendukung konservasi dan edukasi berbasis pengenalan citra.

2. METODE PENELITIAN

Pendekatan kuantitatif diterapkan dalam penelitian ini dengan metode dukungan eksperimen terhadap dataset. Proses eksperimen dilakukan dengan melatih dan menguji model menggunakan berbagai konfigurasi *hyperparameter* guna memperoleh performa terbaik. Tahapan penelitian meliputi pengumpulan data, split atau pemisahan data, *pre-processing*, penerapan model *pre-trained*, pelatihan model, serta evaluasi model.



Gambar 1 Tahapan Penelitian

2.1. Pengumpulan Data

Pada tahap ini, data diperoleh dari sumber terbuka, yaitu Kaggle. Dataset terdiri dari 14.481 data yang terbagi menjadi data latih dan data validasi, masing-masing terdapat 29 kelas atau kategori tanaman hias tropis. Pada masing-masing kelas atau kategori, terdapat beragam jenis data yang telah dimodifikasi melalui teknik augmentasi untuk memperkaya variasi gambar, yaitu *rotate*, *scaled*, *flip*, *noise*, dan *grayscale*. Tabel 1 menunjukkan contoh salah satu data sampel dari tanaman hias yang mengalami augmentasi.

Tabel 1 Sampel contoh proses gambar tanaman hias tropis

No	Jenis augmentasi	Gambar
1	<i>Rotate</i>	
2	<i>Scaled</i>	
3	<i>Flip</i>	
4	<i>Noise</i>	
5	<i>Grayscale</i>	

Langkah berikutnya adalah melakukan identifikasi serta *cleaning* atau pembersihan dataset guna menjamin konsistensi data yang digunakan dalam proses pelatihan model. Pada tahap ini, data dengan kelas atau kategori yang tidak sesuai dengan jenis tanaman hias tropis akan dihapus untuk memastikan bahwa dataset hanya berisi gambar tanaman hias tropis saja.

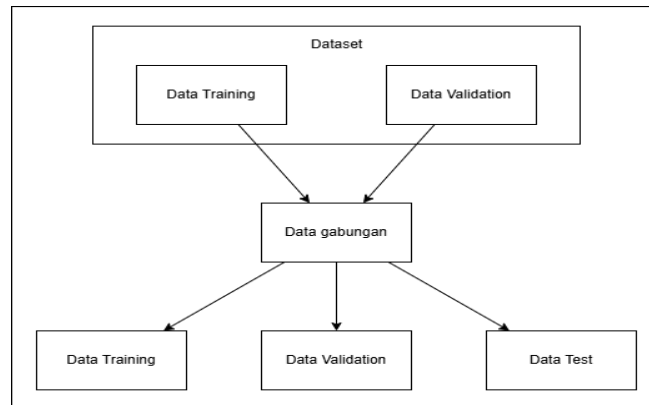
Setelah dilakukan *cleaning* data, didapat hasil akhir dataset dengan total 12.473 data, yang terdiri dari 25 kelas atau kategori tanaman hias tropis. Dataset tersebut terdiri atas 9.973 data untuk pelatihan dan 2.500 data untuk pengujian, dengan rincian lengkap yang disajikan pada Tabel 2.

Tabel 2 Rincian dataset tanaman hias tropis

No	Kategori	Jumlah data	
		Data Latih	Data Uji
1	Anggrek Potong	400	100
2	Anggrek Pot	400	100
3	Anthurium Bunga	400	100
4	Anthurium Daun	400	100
5	Balanceng	400	100
6	Bromelia	400	100
7	Bugenvil	400	100
8	Dracaena	400	100
9	Euphorbia	400	100
10	Hanjuang	400	100
11	Herbras	400	100
12	Kamboja Jepang	400	100
13	Keladi Hias	400	100
14	Mawar	400	100
15	Melati	400	100
16	Monstera	400	100
17	Pakis	373	100
18	Palem	400	100
19	Pedang-Pedangan	400	100
20	Philodendron	400	100
21	Pisang-pisangan	400	100
22	Puring	400	100
23	Sedap Malam	400	100
24	Soka	400	100
25	Sri Rejeki	400	100

2.2. Split data

Pada tahap ini, dataset dipisahkan dalam tiga pembagian, yaitu untuk data *training*, validasi, dan pengujian, dengan proporsi pembagian sebesar 80:10:10. Proses split data seperti pada Gambar 2 untuk memastikan distribusi dan generalisasi data pada tiap kelas dan kategori tetap seimbang dan tidak terjadi bias pada model.




Gambar 2 Proses Split Data

Dataset awal telah dipisahkan menjadi data *training* dan data validasi, di mana setiap kelas mencakup 400 data pelatihan dan 100 data validasi. Selanjutnya, kedua jenis data tersebut digabung kembali berdasarkan kelasnya sebelum dilakukan pemisahan ulang menjadi tiga *subset*, yaitu data *training*, validasi, dan *test*, sesuai dengan proporsi yang telah ditentukan. Proses ini dilakukan dengan memastikan tidak ada duplikasi gambar di antara subset yang terbentuk. Setelah proses split data dilakukan, diperoleh tiga subset dengan total 12500 data, yang terdiri dari 10.000 data *training*, 1250 data validasi, dan 1250 data *test*.

2.3. Pre-processing


Pada tahap *pre-processing*, dataset dipersiapkan agar memiliki format yang konsisten sebelum digunakan dalam pelatihan model. Proses ini mencakup *resizing* gambar ke ukuran 240x240 piksel serta normalisasi menggunakan metode *min-max scaling*, yang menyesuaikan nilai piksel dari skala 0-255 ke dalam rentang 0-1. Normalisasi dilakukan dengan tujuan untuk menyelaraskan data dalam rentang atau jangkauan yang sama agar lebih seimbang [12][13].



Gambar 3 Diagram Blok Model Hibrida CNN-SVM

2.4. Implementasi Model Pre-trained

Hasil dari *pre-processing* akan dilanjutkan ke tahapan ini. Penerapan arsitektur EfficientNet-B1 sebagai model *pre-trained*, telah dilatih sebelumnya menggunakan dataset ImageNet. Pendekatan *feature extraction* diterapkan untuk memanfaatkan fitur-fitur representatif yang telah dipelajari model tersebut, sehingga proses pelatihan menjadi lebih efisien dan akurasi meningkat meskipun dataset terbatas [14].



Gambar 3 Proses implementasi model *Pre-trained*

2.4.1 Muat model EfficientNet-B1

Pada tahap ini, model EfficientNet-B1 dimuat dari pustaka *TensorFlow Keras Applications* dengan bobot (*weights*) yang telah dilatih di dataset ImageNet. Model dimuat tanpa *top layer* (lapisan klasifikasi akhir), karena lapisan tersebut akan diganti dengan lapisan kustom yang sesuai dengan jumlah kelas pada dataset tanaman hias tropis.

2.4.2 Bekukan layer dasar model pre-trained


Layer-layer dasar EfficientNet-B1 yang telah terlatih tidak diperbarui selama proses pelatihan awal (*frozen*). Hal ini bertujuan agar fitur umum seperti tepi, tekstur, dan pola bentuk yang telah dipelajari dari ImageNet tetap dipertahankan. Dengan membekukan layer dasar, pelatihan akan lebih cepat dan model tidak mengalami *catastrophic forgetting* terhadap fitur penting yang sudah dimiliki.

2.4.3 Layer Custom

Tahap ini menambahkan lapisan baru untuk menyesuaikan model dengan dataset yang digunakan. Struktur layer *custom* meliputi GlobalAveragePooling2D, yang mereduksi dimensi fitur menjadi satu nilai per channel. Dense(256, aktivasi ReLU) dan Dense(128, aktivasi ReLU), merupakan lapisan *fully connected* untuk mempelajari kombinasi fitur yang lebih kompleks. Dropout(0.5) diberikan untuk mengurangi *overfitting* dengan menonaktifkan sebagian neuron secara acak saat pelatihan. L2 *Regularization* diterapkan untuk membatasi bobot neuron agar tidak terlalu besar. Dense(25, aktivasi Softmax), merupakan lapisan keluaran dengan 25 neuron (jumlah kelas tanaman hias tropis).

2.4.4 Kompilasi Model

Model yang telah dibentuk kemudian dikompilasi menggunakan *Optimizer Adam*, karena adaptif dan cepat dalam konvergensi dan *Loss function (Categorical Cross-Entropy)*, menyesuaikan untuk permasalahan klasifikasi multi-kelas. Metrik evaluasi untuk menentukan *Accuracy*, dalam menilai performa model selama pelatihan. Hasil dari implementasi model *pre-trained* disajikan pada Gambar 5.



Gambar 4. Arsitektur CNN setelah modifikasi

2.5. Training Model

Proses pelatihan model dilakukan menggunakan dataset untuk melatih model dan data validasi untuk mengevaluasi performanya pada setiap epoch. Pada proses pelatihan ini, beberapa *hyperparameter* yang ditetapkan meliputi *learning rate*, *batch size*, *epochs* serta *L2 Regularizer*. *Hyperparameter tuning* dilakukan guna menemukan kombinasi terbaik yang dapat memaksimalkan akurasi dan stabilitas model [15]. Selain itu, *early stopping* diterapkan untuk menghentikan pelatihan jika kinerja model pada data validasi tidak meningkat dalam 5 *epoch* terakhir. Dengan *hyperparameter* tuning dan pemilihan *optimizer* serta *loss function* yang tepat, diharapkan model mampu melakukan klasifikasi tanaman hias tropis secara optimal.

2.6. Evaluasi Model

Proses evaluasi dilakukan menggunakan data *test* untuk mengukur performa model yang telah dilatih [16]. Evaluasi model dilakukan dengan memanfaatkan *confusion matrix* serta metrik akurasi, *precision*, *recall*, dan *F1-score*. Nilai metrik yang diperoleh kemudian dianalisis dengan membandingkannya terhadap batas nilai yang telah ditetapkan untuk menilai apakah model memiliki kinerja yang optimal dan dapat digunakan.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Training

Proses eksperimen dalam mengembangkan model klasifikasi tanaman hias tropis dengan menerapkan arsitektur pre-trained EfficientNet-B1 dilakukan menggunakan layanan *Google Colab Pro* dengan tipe *hardware* TPU v2-8, serta memanfaatkan beberapa *library Python*, seperti *Tensorflow*, *Keras*, *Matplotlib* dan *Sklearn*. Selama proses perbaikan model, penulis melakukan eksperimen dengan membuat 7 skenario pelatihan dengan kombinasi *hyperparameter* tuning yang berbeda di setiap skenarionya yaitu skenario 1 (S1) hingga skenario 7 (S7).

Tabel 3 Perbandingan 7 skenario dengan *hyperparameter tuning*

Skenario	Learning Rate	Batch Size		Epoch	L2 Regularization
		Training	Validation dan Test		
S1	0,001	32	16	10	-
S2	0,0001	64	32	20	-
S3	0,0001	64	32	30	-
S4	0,0001	64	32	20	0,01
S5	0,0001	64	32	30	0,01
S6	0,0001	64	32	20	0,1
7S	0,0001	64	32	20	0,001


Setelah model selesai dilatih, diperoleh nilai akurasi dan loss untuk data *training* serta validasi. Nilai akurasi dan *loss* pada *epoch* terakhir digunakan sebagai indikator awal untuk menilai performa model terhadap data *training* dan validasi. Hasil perbandingan dari *training* jaringan ditunjukkan pada Tabel 4.

Berdasarkan Tabel 4, hasil pelatihan menunjukkan bahwa skenario S1 memberikan performa terbaik dengan akurasi training sebesar 0,9888 dan akurasi validasi 0,9587 serta nilai loss yang rendah, menandakan model stabil dan mampu melakukan generalisasi dengan baik. Skenario S2 dan S3 menunjukkan akurasi yang cukup tinggi namun mengalami sedikit *overfitting*, terlihat dari selisih akurasi antara data *training* dan validasi.

Tabel 4 Perbandingan hasil *Training* 7 skenario

No	Training		Validasi	
	Akurasi	Loss	Akurasi	Loss
S1	0,9888	0,0354	0,9587	0,1320
S2	0,9579	0,1796	0,8752	0,4227
S3	0,9708	0,1155	0,8896	0,3940
S4	0,9641	2,0155	0,8640	2,2949
S5	0,9823	0,9638	0,8752	1,3627
S6	0,9778	0,4069	0,8672	0,8639
S7	0,9537	0,7103	0,8688	0,9906

Pada S4, nilai loss yang tinggi mengindikasikan proses pelatihan tidak stabil, kemungkinan akibat parameter pelatihan yang tidak optimal. S5 dan S6 memperlihatkan kecenderungan *overfitting*, di mana model terlalu menyesuaikan diri dengan data *training* namun kurang pada validasi. S7 menunjukkan gejala *underfitting* ringan dengan akurasi relatif rendah. Secara keseluruhan, S1 menjadi skenario paling optimal karena menghasilkan keseimbangan terbaik antara akurasi dan loss pada data *training* maupun validasi. Visualisasi *training* ditunjukkan Gambar 5.



Gambar 5 Grafik *training* jaringan pada skenario 1(S1)

Berdasarkan Gambar 6, menunjukkan grafik akurasi dan loss selama pelatihan model EfficientNet-B1. Grafik akurasi memperlihatkan peningkatan signifikan pada awal *epoch* hingga stabil di kisaran 0,97 untuk data *training* dan 0,95 untuk validasi, menandakan model belajar dengan baik tanpa *overfitting* yang berarti. Grafik loss juga menunjukkan penurunan tajam di awal pelatihan dan stabil pada nilai rendah, mengindikasikan proses konvergensi yang baik. Secara keseluruhan, model menunjukkan performa stabil dengan akurasi tinggi dan kemampuan generalisasi yang baik terhadap data validasi.


3.2 Evaluasi Model

Tabel 5 menunjukkan hasil perbandingan 7 skenario evaluasi pengujian dengan *confusion matrix* pada hasil evaluasi data uji untuk menentukan menghitung metrik akurasi, *precision*, *recall*, dan *F1-Score*.

Tabel 5 Perbandingan hasil evaluasi dengan *Confusion Matrix*

No	Akurasi	Precision	Recall	F1-Score
1	0,98	0,982	0,98	0,9792
2	0,8632	0,8854	0,8632	0,8579
3	0,896	0,9034	0,8960	0,8911
4	0,876	0,8764	0,876	0,8657
5	0,8752	0,8812	0,8752	0,8668
6	0,864	0,8678	0,864	0,8511
7	0,8744	0,8826	0,8744	0,8661

Berdasarkan Tabel 5, hasil evaluasi menggunakan *Confusion Matrix* menunjukkan bahwa skenario 1 memiliki performa terbaik dengan akurasi 0,98, *precision* 0,982, *recall* 0,98, dan *F1-score* 0,9792. Nilai metrik yang tinggi dan seimbang menandakan model mampu mengklasifikasikan data dengan sangat baik tanpa bias terhadap kelas tertentu. Sementara itu, skenario 2 hingga 7 memiliki nilai akurasi berkisar antara 0,86–0,89 dengan *F1-score* yang relatif seimbang, namun sedikit lebih rendah dibanding S1. Hal ini menunjukkan bahwa meskipun semua model berfungsi cukup baik, skenario 1 memberikan hasil paling optimal dan stabil dalam mendeteksi serta mengklasifikasikan citra tanaman hias tropis. Secara keseluruhan, model terbaik dihasilkan oleh skenario 1 karena memiliki keseimbangan yang optimal antara *precision*, *recall*, dan *F1-Score*. Hasil pemetaan kelas hasil dari proses *training* dari skenario 1 seperti ditunjukkan pada Gambar 7.



Gambar 6 *Confusion Matrix* pada Model 1

Berdasarkan Gambar 7, menunjukkan *Confusion Matrix untuk* skenario 1, yang menggambarkan hasil prediksi model terhadap 25 kelas tanaman hias tropis. Matrik menampilkan distribusi prediksi yang seluruhnya terkonsentrasi pada diagonal utama, menandakan bahwa setiap kelas berhasil diklasifikasikan dengan benar. Hal ini menunjukkan bahwa model memiliki akurasi yang sangat tinggi (0,98) serta kemampuan klasifikasi yang konsisten untuk seluruh kategori. Dengan demikian, model pada skenario 1 dapat dikatakan sangat efektif dan andal dalam mengenali citra tanaman hias tropis.

3.3 Pengujian

Tabel 6 menunjukkan hasil pengujian lanjut yang dilakukan terhadap setiap kelas dengan 7 skenario terhadap data baru. Hal ini untuk mengetahui seberapa model terhadap data baru untuk mengenali kelasnya masing-masing.

Berdasarkan Tabel 6, hasil pengujian terhadap 25 kelas tanaman hias tropis pada tujuh skenario menunjukkan variasi tingkat keberhasilan model dalam mengenali setiap kategori. Skenario S7 memberikan hasil terbaik dengan tingkat keberhasilan 84%, di mana 21 kelas berhasil dikenali dengan benar. Disusul oleh S2 dan S4 dengan akurasi masing-masing 80%, menunjukkan bahwa model pada skenario tersebut juga mampu melakukan klasifikasi dengan baik. Sementara itu, S1 memiliki akurasi terendah sebesar 60%, meskipun pada evaluasi umum sebelumnya (*Confusion Matrix* dan metrik evaluasi) menunjukkan hasil tinggi, hal ini mengindikasikan bahwa performa per kelas masih bervariasi.

Tabel 6. Hasil pengujian setiap kelas tanaman pada 7 skenario

Kategori	Pengujian						
	S1	S2	S3	S4	S5	S6	S7
Anggrek Potong	✓	✓	✓	✓	✓	✓	✓
Anggrek Pot	x	x	x	x	x	x	x
Anthurium Bunga	x	x	x	x	x	x	x
Anthurium Daun	x	x	x	x	x	✓	x
Balanceng	✓	✓	✓	✓	✓	✓	✓
Bromelia	✓	x	x	x	x	✓	✓
Bugenvil	✓	✓	✓	✓	✓	✓	✓
Dracaena	x	✓	x	✓	✓	x	✓
Euphorbia	x	✓	x	✓	x	✓	✓
Hanjuang	x	✓	✓	✓	✓	✓	✓
Herbras	✓	✓	✓	✓	✓	✓	✓
Kamboja Jepang	✓	✓	✓	✓	✓	✓	✓
Keladi Hias	✓	✓	✓	✓	✓	✓	✓
Mawar	✓	✓	✓	✓	✓	✓	✓
Melati	x	✓	✓	✓	✓	x	✓
Monstera	✓	✓	✓	✓	✓	✓	✓
Pakis	✓	✓	✓	✓	✓	✓	✓
Palem	✓	✓	✓	✓	✓	✓	✓
Pedang-Pedangan	x	✓	✓	✓	✓	✓	✓
Philodendron	✓	✓	✓	✓	✓	✓	✓
Pisang-pisangan	✓	✓	✓	✓	✓	✓	✓
Puring	x	✓	✓	✓	✓	✓	✓
Sedap Malam	✓	✓	✓	✓	✓	✓	✓
Soka	✓	✓	✓	✓	✓	x	✓
Sri Rejeki	x	x	x	x	x	x	x
Total Benar	15	20	18	20	19	19	21
Total Salah	10	5	7	5	6	6	4
Persentase	60%	80%	72%	80%	76%	76%	84%

Beberapa kelas seperti Anggrek Pot dan Sri Rejeki tidak berhasil diklasifikasikan dengan benar pada seluruh skenario, menandakan adanya kesulitan model dalam mengenali ciri visual khas dari kelas tersebut, kemungkinan akibat kemiripan bentuk atau warna dengan kelas lain. Sebaliknya, kelas seperti Balanceng, Bugenvil, Herbras, Kamboja Jepang, Mawar, Monstera, dan Palem berhasil dikenali secara konsisten di semua skenario, menunjukkan bahwa fitur visualnya mudah dipelajari oleh model. Secara keseluruhan, hasil ini menunjukkan bahwa performa model bervariasi antar kelas, dan skenario S7 memberikan keseimbangan terbaik antara akurasi keseluruhan dan kemampuan klasifikasi lintas kategori. Kemampuan model perlu diujikan dengan data dengan varian non tanaman hias, seperti ditunjukkan dari hasil Tabel 7.

Tabel 7. Hasil Pengujian pada Gambar Non-Tanaman Hias Tropis

Kategori	Pengujian						
	S1	S2	S3	S4	S5	S6	S7
Botol	x	✓	✓	x	x	✓	✓
Keranjang Belanja	x	X	✓	✓	x	✓	x
Kado	x	✓	x	✓	x	x	✓
Sampah	x	x	x	x	x	x	✓
Kaktus	x	✓	x	x	✓	x	x

Berdasarkan uji pada gambar **non-tanaman** (Tabel 7) menunjukkan **S7** paling baik: benar mengenali **4 dari 5** kategori, menandakan generalisasi dan pemisahan tanaman vs non-tanaman yang konsisten. **S1** terendah (gagal mengenali seluruh kategori), mengindikasikan overfokus pada pola tanaman. **S2, S4, S6** berada di tengah (3 kategori benar), sedangkan **S3, S5** hanya sebagian kecil terdeteksi. Temuan ini menegaskan pengaruh konfigurasi pelatihan terhadap sensitivitas OOD; perbaikan disarankan melalui penyeimbangan/penambahan data per kelas, penambahan data non-kelas (negative samples), dan pengetatan ambang kepercayaan.

4. KESIMPULAN

Penerapan EfficientNet-B1 pre-trained mempercepat pelatihan tetapi belum cukup mendongkrak akurasi pada klasifikasi tanaman hias tropis. Peningkatan kinerja terutama dipengaruhi penyetelan hyperparameter (learning rate, batch size, epoch, L2), dengan evaluasi (confusion matrix; akurasi, presisi, recall, F1) menunjukkan sebagian besar kelas terprediksi baik meski beberapa tetap sulit akibat variasi data yang terbatas. Dari tujuh skenario, **Skenario 1** terbaik dengan akurasi **98%** dan **F1 97,92%**, serta presisi–recall seimbang; karenanya **model S1** direkomendasikan karena memberi keseimbangan metrik yang optimal.

5. SARAN

Keterbatasan utama penelitian ini adalah variasi data yang kurang, sehingga beberapa kelas masih keliru terprediksi. Ke depan, tambahkan gambar asli, terapkan augmentasi untuk menyeimbangkan distribusi, serta lakukan hyperparameter tuning (grid/random search). Pertimbangkan model pre-trained lain atau varian EfficientNet yang lebih baru guna meningkatkan akurasi dan kesiapan penerapan pada kebutuhan nyata identifikasi tanaman hias.

DAFTAR PUSTAKA

- [1] T. Safitri, T. Rahmawati, S. M. Wafidah, T. A. Mu'tmainah, and E. R. S. Rendra, "Analisis potensi pemanfaatan flora lokal dalam bisnis florist: Studi Gisy Florist di Kecamatan Mangkubumi Kota Tasikmalaya," *Tolis Ilmiah: Jurnal Penelitian*, 2024.
- [2] D. Udjulawa, "Klasifikasi tanaman hias berdasarkan tekstur daun menggunakan metode SVM dan fitur GLCM," *Klik – Jurnal Ilmu Komputer*, vol. 3, no. 2, pp. 121–127, 2023, doi:

- 10.56869/klik.v3i2.418.
- [3] L. Alzubaidi *et al.*, “Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions,” *Journal of Big Data*, vol. 8, 2021.
 - [4] I. Aryadi and A. Suhendar, “Implementasi arsitektur Xception dalam menentukan kematangan tandan buah segar kelapa sawit,” *Jurnal JUTISI*, vol. 13, no. 3, pp. 2235–2247, 2024.
 - [5] M. Z. Ersyad, K. N. Ramadhani, and A. Arifianto, “Pengenalan bentuk tangan dengan convolutional neural network (CNN),” *e-Proceeding of Engineering*, vol. 7, no. 2, pp. 8212–8222, 2020.
 - [6] A. M. Tama and R. C. N. Santi, “Klasifikasi jenis tanaman hias menggunakan metode convolutional neural network (CNN),” *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 6, no. 2, pp. 764–770, 2023.
 - [7] Purwanto and Sumardi, “Perancangan klasifikasi tanaman herbal menggunakan transfer learning pada algoritma convolutional neural network (CNN),” *Jurnal INFOKAM*, vol. 18, no. 2, 2022.
 - [8] A. Hardirega, I. Jaelani, and Minarto, “Implementasi convolutional neural network (CNN) klasifikasi motif batik menggunakan EfficientNet-B1,” *Jurnal Mahasiswa Teknik Informatika (JATI)*, vol. 8, no. 5, 2024.
 - [9] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *arXiv preprint*, 2020.
 - [10] Y. Mardianto, T. Dewi, and P. Risma, “Analisis klasifikasi kematangan buah tomat dengan pendekatan transfer learning model EfficientNet,” *Jurnal Techno Bahari*, vol. 11, no. 1, pp. 20–25, 2024.
 - [11] A. Rahman, M. Salim, and I. Riadi, “Klasifikasi citra spesies bunga di Indonesia berbasis convolutional neural network menggunakan teknik transfer learning,” *Jurnal JSECI*, vol. 2, no. 2, pp. 92–100, 2025.
 - [12] G. A. B. Suryanegara, Adiwijaya, and M. D. Purbolaksono, “Peningkatan hasil klasifikasi pada algoritma Random Forest untuk deteksi pasien penderita diabetes menggunakan metode normalisasi,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 114–122, 2021.
 - [13] M. Widyarningsih, T. K. Priyambodo, M. E. Wibowo, and M. Kamal, “Optimization contrast enhancement and noise reduction for semantic segmentation of oil palm aerial imagery,” *International Journal of Intelligent Engineering and Systems*, vol. 16, no. 1, pp. 597–609, 2023. (ISSN 2185-310X)
 - [14] B. Falakhi, F. F. Achmal, M. I. Rizaldi, R. R. Athallah, and N. Yudistira, “Perbandingan model AlexNet dan ResNet dalam klasifikasi citra bunga memanfaatkan transfer learning,” *Jurnal Ilmu Komputer dan Agri-Informatika*, 2022.
 - [15] K. A. Wulandari, A. R. Nugraha, A. Luthfiarta, and L. R. Nisa, “Peningkatan akurasi deteksi dini penyakit Parkinson melalui pendekatan ensemble learning dan seleksi fitur optimal,” *Edumatic: Jurnal Pendidikan Informatika*, 2024.
 - [16] G. Y. Alhafis, J. Jasril, S. Sanjaya, F. Syafria, and E. Budianita, “Klasifikasi citra daging sapi dan daging babi menggunakan ekstraksi ciri dan convolutional neural network,” *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 3, pp. 653–660, 2022.