

Evaluasi Komparatif Model Transfer learning untuk Klasifikasi Tanaman Aquascape

Muhammad Ilham Ashiddiq¹, Ni'matul Ma'muriyah², Sabariman², Lesley Peterson Lee¹

¹ Prodi Teknologi Informasi, Fakultas Ilmu Komputer, Universitas Internasional Batam, Jalan Gajah Mada, Baloi Sei Ladi, Batam, Indonesia

² Prodi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Internasional Batam, Jalan Gajah Mada, Baloi Sei Ladi, Batam, Indonesia

ARTICLE INFO

Keywords:

Aquascape, Image Classification, Image Processing, Convolutional Neural Network, Transfer Learning

Received: May 20, 2026

Revised: July 11, 2026

Accepted: July 15, 2026

*Corresponding author:

E-mail: ilham.tresnawan@uib.ac.id
(Muhamamad Ilham Ashiddiq)

DOI: [10.37253/telcomatics.v11i1.12440](https://doi.org/10.37253/telcomatics.v11i1.12440)

ABSTRACT

The popularity of *aquascaping* has increased significantly in recent years. However, beginners often face difficulties in identifying aquatic plant species due to their highly similar visual characteristics, which may lead to improper plant care. This study evaluates and compares the performance of three *Convolutional Neural Network (CNN)* architectures, namely *MobileNetV3 Large*, *ResNet18*, and *EfficientNet-B0*, for classifying six aquascape plant species: *Anubias*, *Bucephalandra*, *Cryptocoryne Wendtii*, *Floaters*, *Hornwort*, and *Vallisneria Spiralis*. The dataset consists of 1,998 images resized to 224×224 pixels and enhanced through data augmentation techniques, including *rotation*, *horizontal flip*, *color jitter*, and *Gaussian blur*, to improve model generalization. The models were trained using the *PyTorch* framework with transfer learning, fine-tuning based on ImageNet pretrained weights, the *AdamW optimizer*, class weighting, and an early stopping strategy. Experimental results show that *ResNet18* achieved the highest test accuracy of 92.7%, followed by *EfficientNet-B0* with 90.3% and *MobileNetV3 Large* with 88.7%. These findings indicate that the residual learning architecture of *ResNet18* is particularly effective for aquatic plant classification on the proposed dataset, while *MobileNetV3 Large* remains a suitable alternative for deployment on resource-constrained devices.

I. PENDAHULUAN

Aquascape merupakan salah satu hobi yang semakin populer dalam beberapa tahun terakhir. Banyak orang mulai tertarik membuat “taman dalam air” yang estetik, memadukan tanaman air, batu, kayu, dan elemen dekoratif lainnya menjadi sebuah komposisi yang menarik untuk dilihat. Tren ini berkembang melalui media sosial seperti *Instagram*, *TikTok*, dan *YouTube*, di mana banyak konten kreator berbagi tank buatan mereka dengan berbagai gaya seperti “*nature aquarium*”, “*Iwagumi*”, atau “*Dutch style*”. Karena daya tarik visual dan sifatnya yang menenangkan, tidak sedikit orang yang baru mencoba hobi ini setelah melihat hasil karya orang lain.

Namun, meskipun terlihat indah dan mudah di internet, aquascape sebenarnya membutuhkan pengetahuan yang cukup mengenai tanaman, cahaya, nutrisi, hingga aliran air. Salah satu kesulitan terbesar yang dialami pemula adalah mengenali jenis tanaman air. Identifikasi tanaman air bukanlah hal yang sepele karena beberapa jenis tanaman memiliki karakteristik morfologi yang sangat mirip. Selain dipengaruhi oleh kemiripan antarspesies, akurasi proses identifikasi juga dipengaruhi oleh perubahan kondisi tanaman setelah ditanam, variasi pencahayaan, dan sudut pengambilan gambar. Faktor-faktor tersebut menyebabkan representasi visual suatu spesies menjadi lebih bervariasi sehingga meningkatkan tingkat kesulitan dalam proses klasifikasi. Faktor-faktor seperti

kemiripan visual antarspesies (*inter-class similarity*), perubahan pencahayaan (*illumination changes*), variasi sudut pandang (*viewpoint variation*), dan perubahan skala objek diketahui menjadi tantangan utama dalam klasifikasi citra tanaman karena dapat menurunkan kemampuan model dalam membedakan spesies yang memiliki karakteristik morfologi serupa [1], [2], [3].

Sebagai contoh, spesies dari genus *Cryptocoryne* menunjukkan variasi bentuk daun yang dipengaruhi oleh kondisi pertumbuhan. Di sisi lain, *Vallisneria spiralis* memiliki morfologi daun yang ramping dan memanjang, sehingga pada kondisi tertentu karakteristik visualnya dapat menyerupai beberapa spesies *Cryptocoryne*. Kemiripan morfologi tersebut meningkatkan tingkat kesulitan dalam proses identifikasi maupun klasifikasi berbasis citra. Selain itu, *Anubias* dan *Bucephalandra* adalah dua jenis tanaman yang sama-sama berdaun lebar dan tebal, dengan warna hijau gelap. Banyak pemula yang salah membedakan keduanya karena perbedaan visualnya cukup halus. Kesalahan-kesalahan ini sering terjadi, terutama jika seseorang membeli tanaman dari toko online yang foto produknya tidak terlalu jelas atau diambil pada kondisi pencahayaan yang tidak ideal. Tantangan serupa juga dilaporkan pada berbagai penelitian klasifikasi tanaman, di mana kemiripan bentuk daun menjadi salah satu penyebab utama terjadinya kesalahan identifikasi [1], [4].

Kesalahan identifikasi tanaman air dapat berdampak pada keberhasilan aquascape secara keseluruhan. Setiap spesies

memiliki kebutuhan yang berbeda, mulai dari intensitas cahaya, kebutuhan CO_2 , sampai jenis substrat yang dibutuhkan. Misalnya, tanaman seperti *Hornwort* memiliki pertumbuhan cepat dan bisa mengambil nutrisi dari kolom air, sedangkan *Anubias* tidak boleh ditanam di substrat karena akarnya dapat membusuk. Jika seseorang salah mengira jenis tanaman yang dimiliki, cara perawatannya pun menjadi salah, dan hasil akhirnya bisa berupa tanaman menguning, meleleh, atau mati seluruhnya. Permasalahan identifikasi spesies tumbuhan tidak hanya berdampak pada aspek budidaya, tetapi juga menjadi tantangan dalam pengembangan sistem klasifikasi berbasis computer vision karena setiap spesies memiliki karakteristik morfologi yang berbeda dan memerlukan penanganan yang sesuai [2], [5].

Perkembangan Artificial Intelligence (AI), khususnya pada bidang *computer vision*, telah mendorong pemanfaatan *Convolutional Neural Network* (CNN) untuk berbagai tugas klasifikasi citra. CNN telah menunjukkan performa yang tinggi pada identifikasi tanaman obat, penyakit daun tanaman, klasifikasi bunga, pengenalan spesies daun, hingga identifikasi tanaman air karena mampu mengekstraksi fitur visual secara otomatis tanpa memerlukan proses ekstraksi fitur secara manual [1], [6], [7], [8], [9], [10], [11].

Salah satu pendekatan yang banyak digunakan dalam pengembangan sistem klasifikasi citra adalah transfer learning, yaitu memanfaatkan model yang telah dilatih sebelumnya pada dataset berskala besar, seperti *ImageNet*, kemudian menyesuaikannya kembali terhadap dataset target. Pendekatan ini terbukti mampu meningkatkan performa klasifikasi pada berbagai aplikasi pengenalan tanaman, khususnya ketika jumlah data pelatihan relatif terbatas [9], [12], [13], [14].

Dalam penelitian ini digunakan tiga arsitektur CNN yang memiliki karakteristik berbeda, yaitu *MobileNetV3 Large*, *ResNet18*, dan *EfficientNet-B0*. *MobileNetV3 Large* dirancang sebagai arsitektur yang ringan dan efisien sehingga sesuai untuk implementasi pada perangkat dengan keterbatasan sumber daya komputasi [15], [16]. *ResNet18* memanfaatkan mekanisme *residual learning* yang mampu meningkatkan stabilitas pelatihan jaringan dalam serta telah menunjukkan performa yang baik pada berbagai tugas identifikasi tanaman, termasuk tanaman air [10], [17], [18]. Sementara itu, *EfficientNet-B0* menerapkan pendekatan *compound scaling* untuk menyeimbangkan kedalaman, lebar, dan resolusi jaringan sehingga mampu menghasilkan akurasi tinggi dengan jumlah parameter yang relatif efisien [19], [13].

Meskipun teknologi klasifikasi citra tanaman telah berkembang pesat, sebagian besar penelitian masih berfokus pada tanaman obat, tanaman pertanian, pohon, maupun flora darat secara umum [9], [2], [20]. Penelitian yang secara khusus mengevaluasi dan membandingkan performa beberapa model transfer learning untuk identifikasi tanaman aquascape masih relatif terbatas, padahal tanaman aquascape memiliki karakteristik morfologi yang mirip sehingga proses identifikasi menjadi lebih menantang.

Selain pada klasifikasi tanaman, CNN juga telah berhasil diterapkan pada sistem *face recognition* berbasis citra, yang menunjukkan kemampuannya dalam mengekstraksi fitur visual secara efektif untuk proses identifikasi objek. Keberhasilan tersebut menunjukkan bahwa CNN merupakan

pendekatan yang fleksibel dan dapat diterapkan pada berbagai permasalahan klasifikasi citra.

Oleh karena itu, penelitian ini bertujuan mengevaluasi dan membandingkan performa tiga model transfer learning, yaitu *MobileNetV3 Large*, *ResNet18*, dan *EfficientNet-B0*, dalam mengklasifikasikan enam jenis tanaman aquascape berdasarkan citra digital. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk menentukan model yang memberikan performa terbaik pada dataset yang digunakan [21].

Penelitian ini memberikan dua kontribusi utama. Pertama, penelitian menyajikan evaluasi komparatif tiga arsitektur transfer learning pada dataset tanaman aquascape yang terdiri atas enam kelas tanaman dengan karakteristik morfologi yang saling menyerupai. Kedua, penelitian memberikan analisis terhadap performa masing-masing arsitektur sehingga dapat menjadi referensi dalam pemilihan model untuk pengembangan sistem identifikasi tanaman aquascape berbasis kecerdasan buatan.

II. TINJAUAN PUSTAKA

Belakangan ini, pemanfaatan teknologi *Computer Vision* dan algoritma *Deep Learning* untuk mengenali jenis tumbuhan melalui citra digital berkembang dengan sangat pesat. Salah satu pendekatan yang banyak digunakan adalah pemanfaatan karakteristik morfologi daun, seperti bentuk dan pola urat daun, sebagai fitur utama untuk proses klasifikasi. Penelitian terdahulu mengembangkan sistem klasifikasi otomatis bernama *AyurLeaf* sebagai solusi atas proses identifikasi manual yang memerlukan waktu lama dan bergantung pada ketersediaan ahli taksonomi [1]. Dengan memanfaatkan arsitektur *AlexNet* yang dikombinasikan dengan metode *Support Vector Machine* (SVM), sistem tersebut memperoleh akurasi sebesar 96,76% pada klasifikasi 40 jenis tanaman obat. Penelitian tersebut juga menunjukkan bahwa daun merupakan objek yang relatif stabil dan tersedia sepanjang tahun, meskipun kemiripan visual antarspesies (*inter-class similarity*) masih menjadi tantangan utama dalam klasifikasi tanaman [1], [2].

Penelitian berskala besar mengenai klasifikasi tanaman herbal Indonesia dilakukan melalui proyek *IndoHerb* dengan membandingkan beberapa arsitektur CNN modern, yaitu *ResNet*, *DenseNet*, *VGG*, *ConvNeXt*, dan *Swin Transformer* [22]. Menggunakan dataset berisi 10.000 gambar dari 100 jenis tanaman, *ConvNeXt* memperoleh performa terbaik dengan akurasi 92,5% melalui penerapan *transfer learning*. Sebaliknya, model yang dilatih dari awal (*training from scratch*) hanya mencapai akurasi 53,9%. Temuan tersebut sejalan dengan beberapa penelitian transfer learning lainnya yang menunjukkan bahwa penggunaan *pretrained weights* secara konsisten menghasilkan performa yang lebih baik dibandingkan pelatihan dari awal (*training from scratch*) [12], [14].

Proses ekstraksi fitur menggunakan *VGG19* pada dataset *Caltech-101* menunjukkan bahwa model *deep learning* masih dapat dipengaruhi oleh variasi sudut pengambilan gambar, rotasi, dan perubahan skala objek [22]. Untuk mengatasinya, penelitian tersebut menggabungkan fitur mendalam dari *VGG19* dengan fitur konvensional seperti *SIFT*, *SURF*, *ORB*, dan *Shi-Tomasi* sebelum diklasifikasikan menggunakan

Random Forest. Pendekatan tersebut menghasilkan akurasi sebesar 93,73% dan menunjukkan bahwa kombinasi strategi ekstraksi fitur dapat meningkatkan performa klasifikasi.

Penerapan *CNN* juga diperluas pada klasifikasi bunga di lingkungan alami [23]. Dengan memanfaatkan *saliency map* dan *luminance map* untuk mengurangi gangguan latar belakang, model *CNN* yang dikembangkan berhasil mencapai akurasi 76,54% pada dataset internal dan 84,02% pada Oxford 102 Flowers. Hasil tersebut menunjukkan bahwa kombinasi fitur mendalam (*deep features*) dan fitur tradisional (*handcrafted features*) masih menjadi pendekatan yang efektif untuk meningkatkan kualitas representasi citra pada kondisi visual yang kompleks.

Sistem klasifikasi tumbuhan lainnya dikembangkan di kawasan Western Ghats, India, menggunakan lebih dari 50.000 citra daun dari 48 spesies [24]. Melalui perbandingan beberapa arsitektur populer, model *VGG16* yang mereka kembangkan memperoleh akurasi 93,79%. Penelitian ini kembali menegaskan bahwa daun merupakan objek yang sesuai untuk proses klasifikasi citra karena karakteristiknya relatif konsisten dibandingkan bagian tanaman lainnya.

Pemanfaatan arsitektur residual juga telah diterapkan pada klasifikasi vegetasi perairan menggunakan *ResNet-50* berbasis *transfer learning* pada perangkat Raspberry Pi 5 untuk mendeteksi tiga jenis tanaman air invasif, di mana sistem tersebut memperoleh akurasi validasi 86,78% serta akurasi pengujian 86,08% [10]. Selain itu, dikembangkan pula model ensemble *Plant-CNN-ViT* yang menggabungkan *Vision Transformer*, *ResNet-50*, *DenseNet-01*, dan *Xception* sehingga berhasil mencapai akurasi 100% pada dataset *Flavia* dan *Swedish Leaf* [24]. Kedua penelitian tersebut menunjukkan bahwa arsitektur berbasis residual memiliki kemampuan yang baik dalam mempelajari representasi fitur visual yang kompleks.

Berdasarkan berbagai penelitian terdahulu, sebagian besar studi masih berfokus pada tanaman obat, tanaman herbal, bunga, daun, maupun spesies pohon [9], [2], [20]. Penelitian yang secara khusus mengevaluasi beberapa arsitektur transfer learning untuk klasifikasi tanaman aquascape masih sangat terbatas, padahal tanaman aquascape memiliki tingkat kemiripan morfologi yang tinggi sehingga proses identifikasi menjadi lebih menantang.

Mengacu pada temuan terkait efektivitas *transfer learning* [25] serta pentingnya variasi data pelatihan [22][6], penelitian ini menerapkan teknik *transfer learning* dan *fine-tuning* menggunakan bobot awal dari ImageNet pada framework PyTorch. Dataset yang digunakan terdiri atas 1.998 gambar yang diproses menjadi ukuran 224×224 piksel dan diperkaya melalui teknik augmentasi data. Ringkasan penelitian terdahulu yang relevan dengan penelitian ini ditunjukkan pada Tabel 1.

III. METODOLOGI PENELITIAN

A. Dataset Penelitian

Dataset yang digunakan pada penelitian ini terdiri atas enam kelas tanaman aquascape, yaitu *Anubias*, *Bucephalandra*, *Cryptocoryne Wendtii*, *Floaters*, *Hornwort*, dan *Vallisneria Spiralis*. Keenam kelas tersebut digunakan sebagai objek klasifikasi untuk mengevaluasi kinerja model

transfer learning. Contoh citra dari masing-masing kelas ditampilkan pada Gambar 1, yang merepresentasikan karakteristik visual setiap kelas. Beberapa kelas memiliki kemiripan bentuk daun, tekstur, maupun warna, sehingga meningkatkan kompleksitas proses klasifikasi. Secara keseluruhan, dataset terdiri dari 1.998 citra, dengan distribusi jumlah sampel pada setiap kelas disajikan pada Tabel 2.

Untuk proses pelatihan dan evaluasi model, dataset dibagi ke dalam tiga subset, yaitu *training*, *validation*, dan *testing* dengan proporsi sekitar 70%, 15%, dan 15% dari keseluruhan dataset. Dari total 1.998 citra, sebanyak 1.398 citra digunakan sebagai data training, 300 citra sebagai data validation, dan 300 citra sebagai data testing. Data training digunakan untuk mengoptimalkan parameter model, sedangkan data validation dimanfaatkan untuk memantau proses pembelajaran, melakukan penyesuaian *hyperparameter*, serta mencegah terjadinya *overfitting* melalui mekanisme *early stopping*. Pembagian dataset lebih detail ditampilkan pada Tabel 3.



Gambar 1. Enam Kelas Tanaman Air, A) Anubias, B) Bucephalandra, C) *Cryptocoryne Wendtii*, D) Floaters, E) *Hornwort*, dan F) *Vallisneria Spiralis*

Tabel 1. Ringkasan Penelitian Terdahulu

Referensi	Metode	Objek Penelitian	Akurasi
[26]	AlexNet + SVM	Tanaman obat	96,76%
[25]	ConvNeXt	Tanaman herbal Indonesia	92,5%
[22]	VGG19 + Random Forest	Caltech-101	93,73%
[23]	CNN	Klasifikasi bunga	84,02%
[27]	VGG16	Flora Western Ghats	93,79%
[28]	ResNet-50	Tanaman air invasif	86,08%

Tabel 2. Total Dataset Penelitian

Kelas Tanaman	Total Gambar
Anubias	465
Bucephalandra	367
Cryptocoryne Wendtii	252
Floaters	352
Vallisneria Spiralis	218
Hornwort	344
Total	1998

Tabel 3. Pembagian Dataset menjadi Data Training, Validasi, dan Testing.

Kelas Tanaman	Training	Validation	Testing
Anubias	325	70	70
Bucephalandra	257	55	55
Cryptocoryne	176	38	38
Wendtii	246	53	53
Floaters	241	52	51
Hornwort	153	32	33
Vallisneria	1398	300	300
Spiralis			
Total			


B. Preprocessing dan Augmentasi Data

Sebelum proses pelatihan dilakukan, seluruh gambar pada dataset melalui tahap preprocessing terlebih dahulu. Tahap preprocessing dilakukan untuk memastikan seluruh gambar memiliki format dan ukuran yang konsisten sebelum diproses oleh model *CNN*. Pada penelitian ini, seluruh gambar diubah ukurannya menjadi 224×224 piksel agar sesuai dengan ukuran input yang digunakan oleh model *MobileNetV3 Large*, *ResNet18*, dan *EfficientNet-B0*. Selain itu, gambar juga dikonversi ke dalam bentuk tensor agar dapat diproses oleh framework *PyTorch*.

Proses augmentasi data diterapkan pada data latih (training data) untuk meningkatkan variasi gambar dan membantu model melakukan generalisasi dengan lebih baik terhadap gambar baru. Beberapa teknik augmentasi yang digunakan meliputi *rotasi gambar*, *horizontal flip*, *color jitter*, dan *gaussian blur*. Augmentasi dilakukan untuk mengurangi kemungkinan model hanya menghafal pola pada data latih (*overfitting*) [29]. Selain augmentasi, normalisasi juga diterapkan pada dataset untuk menstandarisasi distribusi nilai piksel gambar. Proses normalisasi dilakukan menggunakan parameter *mean* dan *standard deviation* dari dataset *ImageNet* karena model yang digunakan memanfaatkan pretrained weights dari *ImageNet*. Dengan demikian, proses pelatihan model menjadi lebih stabil dan sesuai dengan distribusi data yang telah digunakan pada tahap pretraining model sebelumnya. Penggunaan parameter *normalisasi ImageNet* dilakukan untuk menjaga kesesuaian distribusi data dengan bobot praplatihan (*pretrained weights*) yang digunakan pada proses *transfer learning* [13], [14].

C. Pipeline Preprocessing dan Model CNN

Gambar 2, menunjukkan alur persiapan data sebelum dilakukan proses klasifikasi menggunakan model *CNN*. Tahapan diawali dengan pengumpulan dataset citra tanaman *aquascape* yang kemudian diubah ukurannya menjadi 224×224 piksel agar sesuai dengan spesifikasi masukan ketiga model yang digunakan. Selanjutnya, dilakukan proses augmentasi data yang meliputi *rotation*, *horizontal flip*, *color jitter*, dan *Gaussian blur* untuk meningkatkan variasi data pelatihan serta mengurangi risiko *overfitting*. Setelah proses augmentasi, citra dikonversi ke dalam bentuk tensor dan dinormalisasi menggunakan nilai mean dan standard deviation dari dataset *ImageNet* agar distribusi data sesuai dengan model praplatihan (*pretrained model*).



Gambar 2. Alur Preprocessing dan Augmentasi Data

Tahap akhir pada pipeline ini adalah memasukkan data yang telah diproses ke dalam tiga arsitektur *CNN*, yaitu *MobileNetV3 Large*, *ResNet18*, dan *EfficientNet-B0*, yang kemudian digunakan pada proses pelatihan dan evaluasi model.

1. *MobileNetV3 Large*: merupakan arsitektur *CNN* yang dirancang untuk memiliki ukuran model yang ringan dan efisien dengan performa klasifikasi yang tetap baik. Model ini cocok digunakan untuk proses klasifikasi gambar dengan kebutuhan komputasi yang lebih rendah dibandingkan model *CNN* yang lebih besar [15], [16].

2. *ResNet18*: *Resnet* merupakan arsitektur *CNN* yang menggunakan konsep residual learning untuk membantu proses pelatihan jaringan yang lebih dalam. Penggunaan residual connection memungkinkan model mempertahankan performa pelatihan dengan lebih stabil dan membantu model mempelajari fitur gambar yang lebih kompleks [10], [17], [18].

3. *EfficientNet-B0*: merupakan arsitektur *CNN* yang menggunakan metode compound scaling, yaitu menyeimbangkan kedalaman, lebar, dan resolusi model secara bersamaan. Pendekatan tersebut memungkinkan model memperoleh performa klasifikasi yang baik dengan penggunaan parameter yang lebih efisien [19], [13].

Tabel 4. Konfigurasi Hyperparameter yang Digunakan pada Seluruh Model

Hyperparameter	Nilai
Input image size	224 × 224 piksel
Batch size	32
Optimizer	AdamW
Learning rate	0.00001
Weight decay	0.00001
Maximum epoch	100
Loss function	Cross Entropy Loss
Pretrained weights	ImageNet
Early stopping	Patience = 5
Framework	PyTorch

D. Konfigurasi Hyperparameter Latihan

Seluruh model, yaitu *MobileNetV3 Large*, *ResNet18*, dan *EfficientNet-B0*, dilatih menggunakan konfigurasi hyperparameter yang sama sebagaimana ditunjukkan pada Tabel 4. Penyamaan konfigurasi ini dilakukan agar perbedaan performa yang diperoleh berasal dari karakteristik masing-masing arsitektur, bukan dari perbedaan pengaturan proses pelatihan.

E. Fine-Tuning Model

Pada penelitian ini digunakan metode *fine-tuning* untuk meningkatkan kemampuan model dalam mengenali tanaman air aquascape. *Fine-tuning* dilakukan dengan memanfaatkan pretrained model yang sebelumnya telah dilatih menggunakan dataset *ImageNet*, kemudian menyesuaikan sebagian parameter model terhadap dataset penelitian.

Pada tahap awal, seluruh parameter model dibekukan (*freeze*) agar bobot pretrained tidak langsung berubah selama proses pelatihan. Selanjutnya, beberapa layer bagian atas (top layers) dan classifier layer dibuka kembali (*unfreeze*) agar model dapat mempelajari fitur yang lebih spesifik terhadap klasifikasi tanaman air aquascape. Proses *fine-tuning* dilakukan pada model *MobileNetV3 Large*, *ResNet18*, dan *EfficientNet-B0* dengan menggunakan learning rate yang lebih kecil dibandingkan proses pelatihan biasa. Penggunaan learning rate yang kecil bertujuan untuk menjaga kestabilan proses pelatihan serta menghindari perubahan bobot pretrained secara terlalu drastis.

Pendekatan *fine-tuning* digunakan karena model pretrained telah memiliki kemampuan dalam mengenali fitur visual dasar seperti *bentuk*, *tekstur*, dan *pola gambar*. Dengan *fine-tuning*, model dapat menyesuaikan fitur-fitur tersebut agar lebih sesuai dengan karakteristik dataset tanaman air yang digunakan pada penelitian ini.

F. Proses Pelatihan Model

Proses pelatihan model dilakukan menggunakan framework *PyTorch* dengan memanfaatkan *GPU* untuk mempercepat komputasi. Pelatihan dilakukan pada tiga model *CNN*, yaitu *MobileNetV3 Large*, *ResNet18*, dan *EfficientNet-B0*. Pada penelitian ini digunakan *optimizer AdamW* untuk melakukan pembaruan bobot model selama proses pelatihan.

Optimizer AdamW dipilih karena mampu memberikan proses optimasi yang stabil serta membantu mengurangi overfitting melalui mekanisme *weight decay*. Seluruh model dilatih menggunakan *batch size* sebesar 32 dengan ukuran input gambar 224 × 224 piksel. Jumlah epoch maksimum yang digunakan pada proses pelatihan adalah 100 epoch. Namun, proses pelatihan tidak selalu berjalan hingga mencapai jumlah epoch maksimum karena diterapkan metode *early stopping*.

Metode *early stopping* digunakan untuk menghentikan proses pelatihan secara otomatis ketika performa model pada data validasi tidak lagi mengalami peningkatan setelah beberapa epoch tertentu. Pendekatan ini bertujuan untuk mengurangi kemungkinan terjadinya overfitting dan menjaga kemampuan generalisasi model terhadap data baru. Selain itu, digunakan *class weighting* pada fungsi *loss* untuk membantu mengurangi pengaruh ketidakseimbangan jumlah data pada setiap kelas tanaman. Dengan demikian, model diharapkan dapat mempelajari seluruh kelas secara lebih seimbang selama proses pelatihan berlangsung [30].

G. Evaluasi Model

Evaluasi model dilakukan menggunakan data pengujian (*testing data*) yang tidak digunakan selama proses pelatihan model. Tahap evaluasi bertujuan untuk mengukur kemampuan generalisasi model dalam melakukan klasifikasi terhadap gambar baru yang belum pernah dilihat sebelumnya. Pada penelitian ini digunakan beberapa metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* digunakan untuk mengukur persentase prediksi yang benar dari keseluruhan data pengujian.

$$Accuracy = \frac{TP}{TP+TN+FP} \quad (1)$$

Precision digunakan untuk mengukur ketepatan model dalam memprediksi suatu kelas tertentu. Nilai *precision* dihitung menggunakan Persamaan (2).

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh data dari kelas yang sesuai.

$$Recal = \frac{TP}{TP+FN} \quad (3)$$

Selain itu, digunakan *F1-score* sebagai kombinasi antara *precision* dan *recall* untuk memberikan evaluasi performa model yang lebih seimbang.

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Penggunaan beberapa metrik evaluasi dilakukan karena *accuracy* saja belum cukup untuk menggambarkan performa model secara menyeluruh, terutama pada dataset dengan distribusi jumlah data yang berbeda pada setiap kelas. Dengan mempertimbangkan *precision*, *recall*, dan *F1-score*, evaluasi model menjadi lebih komprehensif dalam menilai kemampuan klasifikasi pada masing-masing kelas.

IV. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan Model

Proses pelatihan dilakukan pada tiga arsitektur *CNN*, yaitu *MobileNetV3 Large*, *ResNet18*, dan *EfficientNet-B0* menggunakan dataset tanaman air *aquascape* yang telah melalui tahap preprocessing dan augmentasi data. Selama proses pelatihan, dilakukan pemantauan terhadap nilai *train loss*, *validation loss*, *train accuracy*, dan *validation accuracy* pada setiap epoch.

Berdasarkan hasil pelatihan, ketiga model menunjukkan peningkatan performa secara bertahap selama proses training berlangsung. Nilai *train loss* dan *validation loss* mengalami penurunan seiring bertambahnya epoch, sedangkan *train accuracy* dan *validation accuracy* mengalami peningkatan. Hal tersebut menunjukkan bahwa model mampu mempelajari pola visual pada dataset dengan cukup baik.

Metode *early stopping* yang diterapkan pada proses pelatihan membantu menghentikan training secara otomatis ketika performa *validation loss* tidak lagi mengalami peningkatan yang signifikan. Dengan demikian, model dapat mengurangi kemungkinan terjadinya *overfitting* terhadap data latih. Berdasarkan hasil pelatihan, model *ResNet18* menunjukkan performa validasi yang paling stabil dibandingkan model lainnya. Selain itu, penggunaan *fine-tuning* pada beberapa layer bagian atas model membantu meningkatkan kemampuan model dalam mempelajari karakteristik spesifik tanaman air *aquascape*.

B. Hasil Pengujian Model

Berdasarkan hasil pengujian, setiap model menunjukkan performa klasifikasi yang berbeda. Hasil evaluasi akhir menunjukkan bahwa model *ResNet18* memperoleh performa terbaik dibandingkan model lainnya. Sementara itu, *EfficientNet-B0* memperoleh performa yang cukup baik dan berada pada posisi kedua, sedangkan *MobileNetV3 Large* memperoleh hasil yang lebih rendah dibandingkan kedua model tersebut. Perbandingan hasil pengujian ketiga model dapat dilihat pada Tabel 5.

C. Analisis dan Diskusi

Berdasarkan Tabel 6, ketiga model *transfer learning* mampu menghasilkan performa klasifikasi yang baik dengan nilai akurasi di atas 88%. Selain itu, nilai *precision*, *recall*, dan *F1-score* pada masing-masing model relatif seimbang terhadap nilai *accuracy*, yang menunjukkan bahwa model tidak hanya menghasilkan prediksi yang akurat, tetapi juga memiliki kemampuan yang konsisten dalam mengenali seluruh kelas tanaman *aquascape*.

Tabel 5. Perbandingan Performa Model CNN pada Data Pengujian

Model	Test Accuracy	Early Stopping Epoch
MobileNetV3 Large	88.7%	77
EfficientNet-B0	90.3%	82
ResNet18	92.7%	55

Tabel 6. Hasil Evaluasi MobileNetV3 Large, ResNet18, dan EfficientNet-B0

Model	Accuracy	Precision	Recall	F1-Score
MobileNetV3 Large	88.7%	0.891	0.887	0.887
EfficientNet-B0	90.3%	0.906	0.903	0.902
ResNet18	92.7%	0.930	0.927	0.927

ResNet18 memperoleh performa terbaik dengan *accuracy* 92,7%, *precision* 0,930, *recall* 0,927, dan *F1-score* 0,927. Nilai yang konsisten pada seluruh metrik tersebut menunjukkan bahwa *ResNet18* memiliki keseimbangan yang baik antara ketepatan prediksi dan kemampuan mengenali setiap kelas tanaman. Hasil ini mengindikasikan bahwa mekanisme *residual learning* pada *ResNet18* mampu mempelajari representasi fitur visual tanaman *aquascape* secara lebih efektif sehingga menghasilkan kemampuan generalisasi yang lebih baik. Temuan ini juga sejalan dengan penelitian sebelumnya yang menunjukkan bahwa penerapan *transfer learning* dan proses *fine-tuning* mampu meningkatkan kemampuan model dalam mengenali karakteristik visual objek secara lebih spesifik [7], [8], [3].

EfficientNet-B0 menempati urutan kedua dengan *accuracy* 90,3%, *precision* 0,906, *recall* 0,903, dan *F1-score* 0,902. Performa tersebut menunjukkan bahwa pendekatan *compound scaling* yang diterapkan pada *EfficientNet-B0* mampu menghasilkan representasi fitur yang baik dengan kompleksitas model yang relatif efisien. Meskipun memiliki akurasi yang sedikit lebih rendah dibandingkan *ResNet18*, selisih performanya hanya sekitar 2,4%, sehingga *EfficientNet-B0* tetap menjadi alternatif yang kompetitif untuk tugas klasifikasi tanaman *aquascape*.

Sementara itu, *MobileNetV3 Large* memperoleh *accuracy* 88,7%, *precision* 0,891, *recall* 0,887, dan *F1-score* 0,887. Walaupun menghasilkan nilai terendah dibandingkan dua model lainnya, seluruh metrik evaluasi masih menunjukkan performa yang baik dan konsisten. Hasil tersebut sesuai dengan karakteristik *MobileNetV3 Large* yang dirancang untuk menghasilkan efisiensi komputasi melalui jumlah parameter yang lebih sedikit, sehingga model ini lebih sesuai untuk implementasi pada perangkat dengan keterbatasan sumber daya, seperti perangkat bergerak (*mobile devices*) atau sistem tertanam (*embedded systems*).

Secara keseluruhan, hasil penelitian menunjukkan bahwa ketiga model *transfer learning* mampu mengklasifikasikan enam jenis tanaman *aquascape* dengan performa yang tinggi. Namun, *ResNet18* memberikan hasil terbaik pada seluruh metrik evaluasi sehingga menjadi model yang paling sesuai untuk dataset yang digunakan pada penelitian ini. Perbedaan performa yang diperoleh juga menunjukkan bahwa karakteristik arsitektur *CNN* berpengaruh terhadap kemampuan model dalam mempelajari kemiripan morfologi antarspesies tanaman *aquascape*, di mana mekanisme *residual learning* pada *ResNet18* memberikan representasi fitur yang lebih diskriminatif dibandingkan *MobileNetV3 Large* maupun *EfficientNet-B0*.

V. KESIMPULAN

Hasil penelitian menunjukkan bahwa penerapan *transfer learning* dengan memanfaatkan *pretrained weights* dari ImageNet mampu meningkatkan kemampuan model dalam mengklasifikasikan tanaman aquascape meskipun jumlah data yang tersedia relatif terbatas. Pendekatan ini memungkinkan model memanfaatkan pengetahuan visual yang telah dipelajari sebelumnya sehingga proses pelatihan menjadi lebih efisien dan tidak perlu dimulai dari awal.

Selain penggunaan *transfer learning*, tahap *preprocessing* dan augmentasi data juga memberikan kontribusi yang penting terhadap performa model. Seluruh gambar diubah menjadi ukuran 224×224 piksel dan diperkaya melalui beberapa teknik augmentasi, seperti rotasi, *horizontal flip*, *color jitter*, dan *gaussian blur*. Penerapan teknik tersebut membantu meningkatkan variasi data pelatihan sehingga model memiliki kemampuan generalisasi yang lebih baik ketika dihadapkan pada gambar yang belum pernah dilihat sebelumnya. Penggunaan *early stopping* juga membantu mengurangi risiko *overfitting* dengan menghentikan proses pelatihan ketika performa pada data validasi tidak lagi mengalami peningkatan.

Berdasarkan hasil eksperimen, *ResNet18* memberikan performa terbaik dibandingkan dua model lainnya dalam tugas klasifikasi enam jenis tanaman aquascape, yaitu *Anubias*, *Bucephalandra*, *Cryptocoryne Wendtii*, *Floater*, *Hornwort*, dan *Vallisneria Spiralis*. Model ini memperoleh akurasi pengujian sebesar 92,7%, lebih tinggi dibandingkan *EfficientNet-B0* dan *MobileNetV3 Large*. Hasil tersebut menunjukkan bahwa mekanisme *residual learning* pada *ResNet18* mampu membantu model mempelajari karakteristik visual tanaman secara efektif setelah proses *fine-tuning* dilakukan.

EfficientNet-B0 menempati urutan kedua dengan akurasi sebesar 90,3% dan menunjukkan performa yang kompetitif dalam proses klasifikasi. Sementara itu, *MobileNetV3 Large* memperoleh akurasi sebesar 88,7%. Meskipun menghasilkan akurasi yang lebih rendah dibandingkan dua model lainnya, *MobileNetV3 Large* memiliki keunggulan dari sisi efisiensi komputasi sehingga tetap berpotensi digunakan pada perangkat dengan sumber daya yang terbatas, seperti aplikasi bergerak (*mobile*) atau sistem tertanam (*embedded system*).

Secara keseluruhan, penelitian ini menunjukkan bahwa peningkatan kualitas dan jumlah dataset, penerapan *fine-tuning*, serta penggunaan strategi pelatihan yang tepat seperti *early stopping* berkontribusi terhadap peningkatan performa klasifikasi. Dari ketiga model yang dievaluasi, *ResNet18* memberikan hasil terbaik pada dataset yang digunakan sehingga menjadi pilihan yang paling sesuai untuk tugas identifikasi tanaman aquascape pada penelitian ini.

VI. REFERENCES

- [1] M. R. Dileep, "AyurLeaf: A Deep Learning Approach for Classification of Medicinal Plants," *TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON)*, pp. 321–325, 2019, doi: <https://doi.org/10.1109/tencon.2019.8929394>.
- [2] J. Wäldchen and P. Mäder, *Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review*, vol. 25, no. 2. Springer Netherlands, 2017. doi: [10.1007/s11831-016-9206-z](https://doi.org/10.1007/s11831-016-9206-z).
- [3] S. R. G. Reddy, G. P. S. Varma, and R. Lakshmi, "Optimized convolutional neural network model for plant species identification from leaf images using computer vision," *International Journal of Speech Technology*, vol. 26 no.1, 2021, doi: [10.1007/s10772-021-09843-x](https://doi.org/10.1007/s10772-021-09843-x).
- [4] N. Kumar, P. N. Belhumeur, A. Biswas, and D. W. Jacobs, "Leafsnap: A Computer Vision System for Automatic Plant Species Identification," *Computer Vision System for Automatic Plant Species Identification*, pp. 502–516, 2012, doi: https://doi.org/10.1007/978-3-642-33709-3_36.
- [5] L. Honghu, "Deep-Learning-Based Automatic Extraction of Aquatic Vegetation from Sentinel-2 Images — A Case Study of," *Remote Sensing MDPI*, 2024, doi: <https://doi.org/10.3390/rs16050867>.
- [6] M. Bansal, M. Kumar, M. Sachdeva, and A. Mittal, "Transfer learning for image classification using VGG19: Caltech - 101 image data set," *Journal of Ambient Intelligence and Humanized Computing*, no. 0123456789, 2021, doi: [10.1007/s12652-021-03488-z](https://doi.org/10.1007/s12652-021-03488-z).
- [7] Y. Liu and F. Tang, "Flower Classification via Convolutional Neural Network," 2016, doi: <https://doi.org/10.5220/0013487000004619>.
- [8] S. Bhat, "Classification of Plant Leaves of Western Ghats using Deep Learning," pp. 0–5, 2021, doi: <https://doi.org/10.1109/discover52564.2021.9663698>.
- [9] M. Salman et al., "Heliyon IndoHerb: Indonesia medicinal plants recognition using transfer learning and deep learning," *Heliyon*, vol. 10, no. 23, p. e40606, 2024, doi: [10.1016/j.heliyon.2024.e40606](https://doi.org/10.1016/j.heliyon.2024.e40606).
- [10] J. Reyes, J. Velasco, and J. Villaverde, "Deep Learning-Based Identification of Invasive Aquatic Plant Species Using Residual Network-50," *engineering proceedings*, 2026, doi: [10.3390/engproc2026134045](https://doi.org/10.3390/engproc2026134045).
- [11] H. Abdullahi, A. Ackley, M. Marvellous, and O. Ebrima, "Early detection of tomato leaf diseases using transformers and transfer learning," *European Journal of Agronomy*, vol. 168, no. March, p. 127625, 2025, doi: [10.1016/j.eja.2025.127625](https://doi.org/10.1016/j.eja.2025.127625).
- [12] R. S. R. Singh, "Zero-Shot Transfer Learning Framework for Plant Leaf Disease Classification," *IEEE Access*, vol. 11, no. December, pp. 143861–143880, 2023, doi: [10.1109/ACCESS.2023.3343759](https://doi.org/10.1109/ACCESS.2023.3343759).
- [13] H. Ali, N. Shifa, R. Benlamri, A. A. Farooque, and R. Yaqub, "A fine tuned EfficientNet-B0 convolutional neural network for accurate and efficient classification of apple leaf diseases," *scientific reports*, pp. 1–26, 2025, doi: <https://doi.org/10.1038/s41598-025-04479-2>.
- [14] U. Amin, M. I. Shahzad, and A. Shahzad, "applied sciences Automatic Freshness Classification Using CNN and Transfer Learning proper," *applied sciences*, 2023, doi: <https://doi.org/10.3390/app13148087>.
- [15] W. Maximiliano and N. Rachmat, "Comparative Analysis of MobileNetV3-Large and Small for Corn Leaf Disease Classification," *Research of Artificial Intelligence*, vol. 5, no. 1, pp. 325–332, 2025, doi: <https://doi.org/10.47709/brilliance.v5i1.6259>.
- [16] H. Pebrian and E. Hartati, "Potato Leaf Disease Classification Using MobileNetV3 Architecture with Adam and Stochastic Gradient Descent Optimizers," *Green Intelligent Systems and Applications*, vol. 6, no. 1, pp. 81–95, 2026, doi: <https://doi.org/10.53623/gisa.v6i1.1063>.
- [17] J. E. Perrin, S. R. Jernigan, J. D. Thayer, A. W. Howell, J. K. Leary, and G. D. Buckner, "Sensor Fusion with Deep Learning for Autonomous Plant Species," *Robotics MDPI*, 2022, doi: <https://doi.org/10.3390/robotics11040068>.
- [18] W. Shafik, A. Tufail, L. C. De Silva, R. Anna, A. Haji, and M. Apong, "Lightweight vision transformer and ResNet-9 models for real-time plant disease detection and pest classification with SHAP explainability," *BMC Plant Biology*, 2026, doi: <https://doi.org/10.1186/s12870-026-08667-8>.
- [19] Y. Arun, "Leaf Classification for Plant Recognition using EfficientNet Architecture," *International Journal of Engineering REsearch & Technology (IJERT)*, vol. 10, no. 11, pp. 68–72, 2021, doi: <https://doi.org/10.1109/icaecc54045.2022.9716637>.
- [20] S. Egli, "CNN-Based Tree Species Classification Using High Resolution RGB Image Data from Automated UAV Observations," *Remote Sensing MDPI*, 2020, doi: [10.3390/rs12233892](https://doi.org/10.3390/rs12233892).
- [21] A. Yulianto and W. Andreas, "Perancangan Prototype Brankas Menggunakan Sistem Pengenalan Wajah dengan Metode Convolutional Neural Network (CNN)," vol. 8, no. 1, 2023, doi: <http://dx.doi.org/10.37253/telcomatics.v8i1.7852>.
- [22] M. Bansal, M. Kumar, M. Sachdeva, and A. Mittal, "Transfer learning for image classification using VGG19: Caltech-101 image data set," *J. Ambient Intell. Humaniz. Comput.*, vol. 14, no. 4, pp. 3609–3620, Apr. 2023, doi: [10.1007/S12652-021-03488-z](https://doi.org/10.1007/S12652-021-03488-z).
- [23] Y. Liu, F. Tang, D. Zhou, Y. Meng, and W. Dong, "Flower classification via convolutional neural network," *Proceedings - 2016 IEEE International Conference on Functional-Structural Plant Growth*

- Modeling, Simulation, Visualization and Applications, FSPMA 2016*, pp. 110–116, Jan. 2017, doi: [10.1109/FSPMA.2016.7818296](https://doi.org/10.1109/FSPMA.2016.7818296).
- [24] C. P. Lee, K. M. Lim, Y. X. Song, and A. Alqahtani, “Plant-CNN-ViT : Plant Classification with Ensemble of Convolutional Neural Networks and Vision Transformer,” *plants*, pp. 1–21, 2023, doi: [10.3390/plants12142642](https://doi.org/10.3390/plants12142642)
- [26] M. S. Ikrar Musyaffa, N. Yudistira, M. A. Rahman, A. H. Basori, A. B. Firdausiah Mansur, and J. Batoro, “IndoHerb: Indonesia medicinal plants recognition using transfer learning and deep learning,” *Heliyon*, vol. 10, no. 23, p. e40606, Dec. 2024, doi: [10.1016/J.HELIYON.2024.E40606](https://doi.org/10.1016/J.HELIYON.2024.E40606).
- [27] Z. Yang, R. O. Sinnott, J. Bailey, and Q. Ke, “arXiv : 2206 . 06544v2 [cs . CV] 6 Oct 2022 A Survey of Automated Data Augmentation Algorithms for Deep Learning-based Image Classification Tasks”, doi: <https://doi.org/10.1007/s10115-023-01853-2>.
- [28] M. N. Razali, N. Arbaiy, and P. Lin, “Optimizing Multiclass Classification Using Convolutional Neural Networks with Class Weights and Early Stopping for Imbalanced Datasets,” *electronics MPDI*, pp. 1–14, 2025, doi: <https://doi.org/10.3390/electronics14040705>.