



Sistem Klasifikasi Keanekaragaman Tanaman Pangan Menggunakan Transfer Learning Pendekatan CNN dan Model Arsitektur EfficientNetB7

Akhmad Fajar Setyawan, Rofi Abul Hasani, Endah Ratna Arumi*

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Muhammadiyah Magelang, Magelang
Jl. Mayjen Bambang Soegeng KM. 5, Glagak, Sumberrejo, Kec. Mertoyudan, Kabupaten Magelang, Jawa Tengah, Indonesia

Email: ¹akhmadfajarsty@unimma.ac.id, ²rofiabul@unimma.ac.id, ^{3,*}arumi@unimma.ac.id

Email Penulis Korespondensi: arumi@unimma.ac.id

Submitted: 15/07/2024; Accepted: 09/10/2024; Published: 13/10/2024

Abstrak—Identifikasi jenis tanaman adalah aspek vital dalam bidang pertanian dan kehutanan yang berpengaruh besar pada produksi pangan, konservasi lingkungan, dan penelitian ilmiah. Sulitnya mengidentifikasi jenis tanaman dapat disebabkan oleh beberapa faktor, seperti keanekaragaman morfologi yang tinggi, kemiripan antar spesies, dan perubahan morfologi tanaman karena kondisi lingkungan yang berbeda. Penelitian ini menggunakan pendekatan deep learning dengan arsitektur EfficientNetB7 untuk mengatasi masalah identifikasi tersebut. Dataset yang digunakan terdiri dari 30.000 gambar yang mewakili 30 jenis tanaman, masing-masing memiliki 1.000 gambar. Model dilatih menggunakan teknik transfer learning dan diuji pada dua skenario klasifikasi dengan 4 kelas tanaman dan 30 kelas tanaman. Hasil menunjukkan akurasi sebesar 97% dengan nilai loss 0.24 untuk 4 kelas, dan akurasi 85% dengan nilai loss 1.1 untuk 30 kelas. Nilai loss yang lebih tinggi pada skenario dengan 30 kelas disebabkan oleh peningkatan kompleksitas dan keragaman data yang lebih besar. Hasil evaluasi menunjukkan bahwa model EfficientNetB7 efektif dalam mengklasifikasikan jenis tanaman dengan tingkat akurasi yang tinggi. Dengan hasil ini, diharapkan model dapat diimplementasikan untuk meningkatkan efisiensi dalam pemeliharaan dan pengelolaan tanaman. Arsitektur Convolutional Neural Network (CNN) berpengaruh pada hasil klasifikasi gambar. CNN umumnya terbagi menjadi dua tahap ekstraksi ciri menggunakan lapisan konvolusi dan klasifikasi menggunakan jaringan saraf tiruan. Pada penelitian ini, model CNN ke enam berhasil mencapai akurasi tertinggi dalam mengklasifikasi motif batik, yaitu sebesar 87,83%. Model ini juga menunjukkan kinerja yang baik pada metrik presisi dan recall.

Kata Kunci: Identifikasi Tanaman; Deep Learning; EfficientNetB7; Transfer Learning; Klasifikasi Gambar; CNN.

Abstract—Plant species identification is a crucial aspect in agriculture and forestry, significantly impacting food production, environmental conservation, and scientific research. The difficulty in identifying plant species can be caused by several factors, such as high morphological diversity, similarities between species, and changes in plant morphology due to different environmental conditions. This study uses a deep learning approach with the EfficientNetB7 architecture to solve the problem of plant identification. The dataset used consists of 30,000 images representing 30 plant species, each with 1,000 images. The model was trained using transfer learning techniques, tested on two scenarios classification with 4 plant classes and 30 plant classes. Results showed an accuracy of 97% with a loss of 0.24 for 4 classes, and an accuracy of 85% with a loss of 1.1 for 30 classes. The higher loss value in the scenario with 30 classes was due to the increased complexity and greater diversity of data. The evaluation results showed that the EfficientNetB7 was effective in classifying plant species with a high level of accuracy. It's expected that model can be implemented to improve efficiency in plant maintenance and management. Convolutional Neural Network (CNN) architecture greatly influences the results of image classification. CNN is generally divided into two stages feature extraction using convolution layers and classification using artificial neural networks. The sixth CNN succeeded in achieving the highest accuracy in batik motifs, which was 87.83%. This model was good performance on precision and recall metrics.

Keywords: Plant Identification; Deep Learning; EfficientNetB7; Transfer Learning; Image Classification; CNN

1. PENDAHULUAN

Identifikasi spesies tanaman pangan merupakan aspek penting dalam pertanian dan kehutanan, yang mempunyai implikasi besar pada berbagai bidang seperti produksi pangan, perlindungan lingkungan, dan penelitian ilmiah. Sebagai bagian tak terpisahkan dari ekosistem, tanaman pangan tidak hanya menjadi sumber makanan, tetapi juga berperan dominan dalam menjaga keseimbangan lingkungan dan mendukung kehidupan berbagai spesies. Namun, identifikasi spesies tanaman masih menjadi tantangan yang belum terselesaikan sepenuhnya dan menjadi perhatian serius.

Data mining merupakan ilmu yang digunakan untuk mengolah informasi dan sekumpulan data yang memanfaatkan kecerdasan dalam membangun pola-pola untuk mengenali karakteristik dari data [1]. Sulitnya mengidentifikasi jenis tanaman pangan dapat disebabkan oleh beberapa faktor, seperti keanekaragaman morfologi yang tinggi, kemiripan antar spesies, dan perubahan morfologi tanaman karena kondisi lingkungan yang berbeda [2]. Proses identifikasi yang akurat dan cepat sangat penting untuk berbagai tujuan, mulai dari pertanian presisi hingga konservasi keanekaragaman hayati.

Pendekatan tradisional dalam identifikasi tanaman pangan seringkali didasarkan pada pengamatan manual oleh para ahli botani, yang memerlukan waktu dan sumber daya yang signifikan serta rentan terhadap kesalahan manusia [3]. Menurut data USDA, identifikasi tanaman pangan yang tidak akurat dapat menurunkan produktivitas tanaman sebesar 15% dan meningkatkan biaya pemeliharaan tanaman hingga 20% [4]. Selain itu, kesalahan dalam

identifikasi tanaman pangan juga dapat menimbulkan permasalahan serius seperti kesalahan penanganan dan penyebaran penyakit tanaman [5].

Untuk mengatasi tantangan ini, penggunaan teknologi untuk mengklasifikasikan tanaman berdasarkan karakteristik dan polanya merupakan solusi yang menjanjikan. Deep learning, sebuah cabang dari machine learning, dapat menjadi solusi teknologi yang efektif [6]. Teknik deep learning yang umum digunakan untuk mengidentifikasi dan mengklasifikasi gambar adalah Convolutional Neural Network (CNN) [7]. Salah satu cara untuk meningkatkan performa model CNN tanpa melalui proses pelatihan ulang dari awal adalah menggunakan pendekatan pembelajaran transfer. Pembelajaran transfer adalah metode mengadaptasi model yang dilatih untuk satu tugas dan menggunakannya kembali untuk tugas lain. Salah satu arsitektur yang paling populer dan banyak digunakan untuk pembelajaran transfer adalah EfficientNetB7, yang memiliki total 66 lapisan [8].

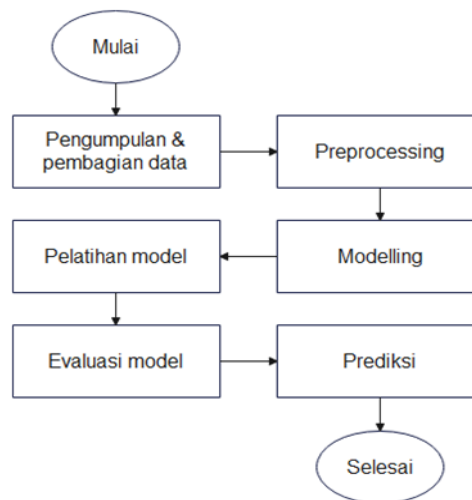
Studi identifikasi jenis tanaman sebelumnya telah dilakukan misalnya yang menggunakan dua pendekatan untuk mengklasifikasikan tanaman menggunakan dataset sebanyak 3000 gambar [9]. Pendekatan pertama menggunakan pengelompokan spektral (SC) dan berbagai ambang batas morfologi dan mencapai akurasi rata-rata 88%. Pendekatan kedua menggunakan arsitektur AlexNet dan metode CNN dan mencapai akurasi rata-rata 87%. Menurut penelitian yang dilakukan oleh Rismayati tahun 2020 [10] arsitektur pembelajaran transfer EfficientNetB7 digunakan untuk mengklasifikasikan varietas buah salak dan membedakan varietas salak yang unggul dan biasa, mencapai hasil akurasi 97%. Penelitian lain bertujuan untuk mengembangkan model klasifikasi tiga kelas terang dan gelap pada retina menggunakan pembelajaran transfer dengan model EfficientNetB7, menghasilkan akurasi sebesar 93% [11]. Demikian pula, studi tentang diagnosis kanker kulit dengan membandingkan efektivitas pembelajaran transfer dengan arsitektur EfficientNetB7 dan EfficientNetB0 mengungkapkan akurasi sebesar 92,5% menggunakan model EfficientNetB7 dan 93,7% menggunakan model EfficientNetB0 [12].

Berdasarkan permasalahan dan data tersebut, kami melakukan pengelompokan tanaman menggunakan pendekatan CNN dalam penelitian Arsitektur Convolutional Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta [13] dan model pembelajaran transfer EfficientNetB7 VGG16 dalam penelitian Klasifikasi Kualitas Buah Salak dengan Transfer Learning Arsitektur VGG16 dengan menambahkan beberapa kondisi pada tahap preprocessing dengan tujuan untuk mendapatkan model EfficientNetB7 yang optimal [14]. Pembaruan penelitian dengan metode transfer learning CNN ini diharapkan lebih efektif dibandingkan metode CNN tradisional karena arsitekturnya terbukti menghemat waktu dan sumber daya komputasi. Penelitian ini diharapkan dapat menghasilkan model multiconditioning yang optimal untuk klasifikasi dalam identifikasi jenis tanaman dan bermanfaat bagi pemangku kepentingan pemeliharaan tanaman.

2. METODOLOGI PENELITIAN

2.1 Pengumpulan Data

Data memanfaatkan kecerdasan dalam membangun pola-pola untuk mengenali karakteristik [1]. Penelitian yang dilakukan menggunakan arsitektur model pembelajaran transfer CNN EfficientNetB7 untuk mengklasifikasikan jenis tanaman dengan memilih 4 label nama tanaman dari total 30 label (jenis tanaman) yang diperoleh dari dataset Kaggle bernama Plants Classification untuk mengklasifikasikannya [15]. Pada penelitian ini terdapat beberapa tahapan dalam klasifikasi citra tanaman, seperti terlihat pada Gambar 1.



Gambar 1. Metodologi Penelitian

Gambar 1 ditampilkan alur metode penelitian yang mencakup beberapa tahap penting. Pertama, pengumpulan data dilakukan untuk mendapatkan 30.000 citra tanaman yang terdiri dari 30 jenis tanaman, masing-masing sebanyak 1.000 gambar. Preprocessing Data mengubah ukuran piksel dan proses augmentasi. Data ini

kemudian dibagi menjadi dua bagian data latih (training data) dan data uji (testing data) dengan perbandingan 80:20[16], dimana 24.000 gambar digunakan untuk pelatihan dan 6.000 gambar untuk pengujian. Setelah itu, dilakukan preprocessing untuk memperbesar variasi dataset melalui augmentasi gambar. Data yang telah diproses kemudian digunakan untuk melatih model EfficientNetB7 menggunakan teknik transfer learning. Proses pelatihan melibatkan optimasi dengan algoritma SGD (Stochastic Gradient Descent) adalah salah satu algoritma optimasi yang sering digunakan dalam machine learning. Algoritma ini bekerja dengan menghitung gradien dari fungsi objektif terhadap parameter model dan memperbarui parameter tersebut secara iteratif dengan mengikuti arah gradien yang menurun, selama 30 epoch, dengan ukuran batch 40. Model yang dihasilkan kemudian diuji dan dievaluasi menggunakan data uji untuk mengukur kinerja klasifikasinya.

Pengumpulan data merupakan proses mendapatkan data citra tanaman untuk dataset yang digunakan dalam penelitian ini. Citra tanaman meliputi 30 jenis tanaman yang akan diidentifikasi. Berdasarkan jenis-jenis tanaman tersebut, dataset ini akan digunakan untuk pembelajaran terawasi (supervised learning) [17].

Tabel 1. Dataset Tanaman

Nama Tanaman	Jumlah Dataset
aloevera	1.000
banana	1.000
...	...
watermelon	1.000
Total	30.000


Pada Tabel 1 menunjukkan dataset berisi kumpulan data yang terstruktur dan disimpan. Berikut daftar lengkap tanamannya: aloevera, banana, bilimbi, cantaloupe, cassava, coconut, corn, cucumber, curcuma, eggplant, galangal, ginger, guava, kale, longbeans, mango, melon, orange, paddy, papaya, peperchili, pineapple, pomelo, shallot, soybeans, spinach, sweetpotatoes, tobacco, waterapple, watermelon. Setiap jenis tanaman memiliki jumlah dataset yang sama, yaitu 1.000 citra per jenis. Setiap sesi pelatihan akan terdapat 30.000 citra yang digunakan dari total keseluruhan 30 jenis tanaman.

2.2 Preprocessing

Tahap preprocessing data pada penelitian ini melibatkan penggunaan metode augmentasi gambar untuk memperkaya variasi dataset. Gambar berukuran 224x224 piksel dengan tiga saluran warna (RGB) diproses menggunakan ImageDataGenerator dari pustaka TensorFlow Keras. Untuk augmentasi data, diterapkan berbagai transformasi termasuk rotasi hingga 40 derajat, pergeseran lebar dan tinggi hingga 20%, shear range 20%, zoom range 20%, serta flipping horizontal dengan fill_mode 'nearest'. Fungsi preprocessing khusus yang digunakan adalah fungsi identitas (scalar) yang mengembalikan gambar tanpa perubahan. Generator data ini dikonfigurasi untuk menghasilkan batch data sebanyak 40 gambar. Data latih dihasilkan menggunakan generator dengan parameter shuffle diaktifkan untuk meningkatkan generalisasi model [18]. Untuk validasi dan pengujian, data generator dikonfigurasi tanpa augmentasi tambahan, namun tetap menggunakan fungsi scalar dan pengaturan shuffle untuk data uji dinonaktifkan agar evaluasi model lebih konsisten.

2.3 Klasifikasi EfficientNetB7

EfficientNetB7 adalah model deep learning untuk klasifikasi gambar. Model ini diperkenalkan dalam paper EfficientNet Rethinking Model Scaling for Convolutional Neural Networks (CNN) oleh Tan dan Le pada tahun 2019[9]. Keunggulan EfficientNetB7 menggunakan teknik scaling yang disebut Compound Scaling, yang secara seimbang meningkatkan kedalaman, lebar, dan resolusi gambar dari model. Teknik ini membuat peningkatan kinerja lebih efektif dibandingkan teknik scaling konvensional. EfficientNetB7 adalah varian terbesar dari keluarga EfficientNet dan menawarkan akurasi sangat tinggi. Struktur Model EfficientNetB7 menggunakan blok standar Convolutional Neural Network yang terdiri dari lapisan convolusi, batch normalization, dan activation functions. Selain itu, arsitektur ini menggabungkan blok-blok MBConv (Mobile Inverted Bottleneck Convolution) untuk efisiensi lebih tinggi. Implementasi dalam Klasifikasi Tanaman EfficientNetB7 digunakan untuk mengidentifikasi dan mengklasifikasikan berbagai jenis tanaman berdasarkan gambar. Model ini mampu menangani berbagai pola dan tekstur kompleks yang ditemukan pada gambar tanaman, menghasilkan akurasi tinggi dalam klasifikasi. Manfaat dengan EfficientNetB7 yaitu klasifikasi tanaman dapat dilakukan lebih efektif, memungkinkan identifikasi jenis tanaman dengan akurasi tinggi, penting untuk aplikasi di bidang pertanian, botani, dan riset ilmiah.



Gambar 2. Arsitektur EfficientNetB7

Gambar 2 menunjukkan arsitektur EfficientNetB7, yang terdiri dari beberapa block convolutional (Block1 hingga Block7). Setiap blok berisi lapisan MBConv (Mobile Inverted Bottleneck Convolution) dengan ukuran kernel yang berbeda (3x3 atau 5x5). Setiap blok memiliki jumlah lapisan yang berbeda-beda, dengan kedalaman yang bertambah seiring dengan proses dari Block1 hingga Block6. Tujuan dari arsitektur ini adalah untuk mengekstraksi fitur gambar secara efisien dan akurat, yang pada akhirnya menghasilkan feature map untuk tugas klasifikasi gambar.

2.4 Evaluasi Model

Evaluasi model merupakan tahap penting dalam penelitian ini untuk menilai kinerja dan efektivitas model klasifikasi tanaman yang telah dilatih. Dalam penelitian ini, model yang digunakan adalah EfficientNetB7, dipilih karena kemampuannya untuk menyeimbangkan akurasi dan efisiensi komputasi. Pada evaluasi model dibagi menjadi 2 skenario:

Tabel 2. Skenario Evaluasi Model

Nama Skenario	Jumlah Tanaman
Skenario 1	4 jenis
Skenario2	30 jenis

Model dilatih dievaluasi menggunakan data uji yang terpisah dari data pelatihan dan validasi. Data uji ini terdiri dari gambar tanaman yang belum pernah dilihat oleh model selama tahap pelatihan. Evaluasi dilakukan menggunakan beberapa metrik utama, yaitu akurasi, precision, recall, dan F1-score. Selain itu, Confusion Matrix digunakan untuk memberikan gambaran lebih rinci tentang kinerja model dalam mengklasifikasikan setiap jenis tanaman.


Akurasi adalah rasio antara jumlah prediksi yang benar dengan total jumlah prediksi, memberikan gambaran umum tentang kinerja model. Precision adalah mengukur seberapa banyak dari prediksi positif yang benar-benar positif, penting untuk memastikan bahwa model tidak menghasilkan banyak prediksi positif yang salah. Recall mengukur seberapa baik model menemukan semua kasus positif yang ada dalam data. F1-score adalah rata-rata harmonis dari precision dan recall, memberikan keseimbangan antara keduanya. Confusion Matrix adalah alat evaluasi yang menunjukkan distribusi prediksi model terhadap kelas yang sebenarnya, membantu mengidentifikasi kelas mana yang sering salah diklasifikasikan oleh model dan memberikan wawasan tentang pola kesalahan.

2.5 Prediksi

Pada penelitian ini, model klasifikasi tanaman yang telah dilatih menggunakan EfficientNetB7 dievaluasi melalui dua skenario prediksi otomatis secara acak dari folder uji (test) dan prediksi manual melalui upload gambar. Kedua skenario ini bertujuan untuk menguji keandalan dan fleksibilitas model dalam berbagai situasi nyata.

2.5.1 Prediksi Otomatis Secara Acak Dari Folder Uji (Test)

Data uji disusun dalam sebuah folder yang berisi gambar-gambar tanaman yang belum pernah dilihat oleh model selama tahap pelatihan. Gambar-gambar ini diambil dari dataset yang telah disiapkan sebelumnya dan dikategorikan sesuai dengan label yang benar. Proses prediksi otomatis dilakukan dengan memilih gambar secara acak dari folder uji (test). Model memproses gambar dan memberikan prediksi berupa label tanaman dan probabilitas.



Gambar 3. Prediksi Gambar Hasil Uji

2.5.2 Prediksi Manual Melalui Upload Gambar

Untuk prediksi manual, sebuah antarmuka pengguna (UI) disiapkan untuk memungkinkan pengguna mengunggah gambar tanaman yang ingin diklasifikasikan. Proses prediksi manual dilakukan dengan mengunggah gambar tanaman melalui antarmuka pengguna. Gambar yang diunggah akan diubah ukurannya agar sesuai dengan input model (224x224 piksel). Gambar kemudian dinormalisasi sesuai dengan skala yang digunakan oleh model selama pelatihan. Model memproses gambar dan memberikan prediksi berupa label tanaman dan probabilitas.



3. HASIL DAN PEMBAHASAN

3.1 Pre-processing

Tahap preprocessing dalam penelitian ini bertujuan untuk memastikan bahwa data citra yang digunakan konsisten dalam hal ukuran dan format sebelum digunakan dalam pelatihan model [18]. Proses ini melibatkan beberapa langkah kritis, yaitu:

a. Resizing

Semua gambar diubah ukurannya menjadi 224x224 piksel, yang merupakan resolusi input standar untuk model EfficientNetB7. Hal ini memastikan bahwa semua gambar memiliki ukuran yang seragam, sehingga model dapat memproses data secara konsisten.

b. Augmentasi Data

Untuk memperkaya variasi dataset, diterapkan augmentasi gambar menggunakan metode seperti rotasi, pergeseran lebar dan tinggi, shear, zoom, serta flipping horizontal. Augmentasi ini bertujuan untuk meningkatkan kemampuan generalisasi model dengan menciptakan variasi data yang lebih besar dari dataset asli.

c. Normalisasi

Gambar yang telah di-resize kemudian dinormalisasi dengan skala nilai piksel antara 0 hingga 1. Normalisasi ini penting untuk memastikan bahwa data input berada dalam rentang yang dapat diterima oleh model deep learning dan membantu dalam konvergensi model selama pelatihan.

d. Pembagian Data

Dataset dibagi menjadi data latih (training) dan data uji (testing) dengan rasio 80:20. Pembagian ini dilakukan untuk memastikan bahwa model dilatih pada sebagian besar data, sementara sisanya digunakan untuk menguji kinerja model secara objektif.

Proses preprocessing yang dilakukan memastikan bahwa data citra yang digunakan dalam pelatihan, validasi, dan pengujian memiliki konsistensi dalam ukuran dan skala. Dengan menggunakan Keras ImageDataGenerator, penelitian ini berhasil menghasilkan data yang siap untuk digunakan dalam pelatihan model deep learning, memastikan kualitas dan keandalan model klasifikasi tanaman yang dikembangkan.

3.2 Klasifikasi Arsitektur EfficientNetB7

Model yang dibuat pada penelitian ini ada model transfer learning arsitektur EfficientNetB7 yang dibangun dengan library Keras. Model ini dilatih menggunakan dataset sebanyak 1.000 gambar per tanaman dengan total 30 tanaman. Ada dua skenario dalam pengujian, pertama adalah dipilih 4 dari 30 tanaman, kedua adalah 30 tanaman. Pelatihan data yang dilakukan dalam penelitian ini menggunakan beberapa hyperparameter seperti optimasi SGD, 30 epoch, ukuran batch size 40 dan mengontrol keluaran log menggunakan verbose 1. Hasil pemodelan data dapat dilihat pada Tabel 3.

Tabel 3. Hasil Ujicoba Setiap Skenario

		Nama Skenario	
		S1	S2
Data Training	Loss	0.19	1.08
	Accuracy	0.97	0.82
Data Validation	Val Loss	0.25	1.42
	Val Accuracy	0.94	0.67
Data Testing	Loss	0.24	1.1
	Accuracy	0.97	0.85

Berdasarkan Tabel 3 skenario 1 (S1) didapatkan hasil akurasi 0.97 atau sebesar 97% dengan loss atau kerugian sebesar 0.24, skenario 2 (S2) didapatkan hasil akurasi 0.85 atau sebesar 85% dengan loss atau kerugian sebesar 1.1. Data loss yang lebih besar pada tabel 2 dibandingkan dengan tabel 1 dapat dijelaskan oleh beberapa faktor berikut

3.2.1 Jumlah Kelas yang Lebih Banyak

Dalam skenario kedua, model dilatih untuk mengklasifikasikan 30 jenis tanaman. Peningkatan jumlah kelas ini menambah kompleksitas masalah klasifikasi, karena model harus mempelajari lebih banyak fitur yang membedakan setiap kelas. Jumlah kelas yang lebih banyak mengharuskan model untuk mengenali perbedaan yang lebih halus antar spesies, yang dapat menyebabkan peningkatan nilai loss jika model tidak mampu mengidentifikasi fitur-fitur ini dengan tepat.

3.2.2 Ukuran Dataset

Ukuran dataset pada skenario kedua (30.000 gambar) jauh lebih besar dibandingkan skenario pertama (4.000 gambar). Meskipun dataset yang lebih besar umumnya membantu model dalam belajar lebih baik, keberagaman

data yang tinggi dalam 30 kelas menambah tantangan dalam pelatihan. Variasi dalam data membuat model harus mampu mengenali pola yang lebih kompleks, yang menuntut lebih banyak data per kelas agar model dapat menggeneralisasi dengan baik[19]

3.2.3 Overfitting atau Underfitting

Overfitting terjadi ketika model terlalu terfokus pada data pelatihan sehingga kehilangan kemampuan untuk menggeneralisasi ke data baru. Dalam skenario dengan 30 kelas, risiko overfitting meningkat karena model mungkin cenderung mengingat data pelatihan yang beragam daripada belajar fitur yang dapat digeneralisasi. Untuk mengatasi hal ini, dilakukan beberapa teknik regulasi seperti dropout dan early stopping. Sebaliknya, underfitting terjadi ketika model tidak cukup kompleks untuk menangkap pola dalam data, yang dapat diatasi dengan penyesuaian arsitektur model dan hyperparameter yang lebih baik.

3.2.4 Kompleksitas dan Keanekaragaman Data

Keanekaragaman data dalam dataset 30 kelas mencakup variasi dalam pencahayaan, sudut pengambilan gambar, dan kondisi lingkungan, yang semuanya menambah kompleksitas dalam proses pelatihan. Model EfficientNetB7 dilatih untuk mengenali pola-pola ini dengan memanfaatkan augmentasi data yang lebih ekstensif dan tuning hyperparameter yang lebih cermat. Namun, peningkatan variabilitas ini juga berarti model harus lebih mampu untuk menggeneralisasi pola dari data yang lebih beragam, yang menuntut peningkatan dalam kapasitas model dan teknik regularisasi.



Gambar 4. Keanekaragaman Klasifikasi Tanaman

3.2. Arsitektur Model dan Hyperparameter

Model EfficientNetB7 menggunakan teknik scaling yang mengoptimalkan kedalaman, lebar, dan resolusi input untuk mencapai kinerja yang lebih baik. Dalam penelitian ini, hyperparameter seperti learning rate, ukuran batch, dan jumlah epoch disesuaikan secara cermat melalui eksperimen untuk menghindari overfitting dan mencapai konvergensi yang stabil. Penggunaan learning rate decay dan optimasi dengan SGD juga dilakukan untuk memastikan bahwa model mampu beradaptasi dengan baik pada data yang lebih kompleks tanpa kehilangan akurasi.

3.3 Hasil Evaluasi Model

Efektivitas seluruh model skenario yang telah dirancang pada tahap sebelumnya akan dianalisis untuk menentukan skenario terbaik. Analisis ini akan menggunakan perhitungan precision, recall, dan F1-score, serta tabel confusion matrix. Berikut adalah rincian evaluasi model yang dilakukan:

3.3.1 Nilai Precision, Recall, dan F1-score

Pada penelitian ini, model EfficientNetB7 mencapai akurasi sebesar 85% pada data pengujian. Tabel berikut menunjukkan nilai precision, recall, dan F1-score untuk masing-masing kelas tanaman:


Tabel 4. Hasil Evaluasi Model Skenario 1

Kelas Tanaman	Precision	Recall	F1-score
aloevera	0.99	0.98	0.98
banana	0.99	0.97	0.98
blimbi	0.90	0.98	0.94
orange	0.98	0.92	0.95

Tabel 5. Hasil Evaluasi Model Skenario 2

Kelas Tanaman	Precision	Recall	F1-score
aloevera	0.89	0.87	0.88
banana	0.85	0.96	0.90
bilimbi	0.72	0.75	0.74
cantaloupe	0.33	0.32	0.32
cassava	0.83	0.82	0.82
coconut	0.86	0.89	0.88
corn	0.95	0.83	0.89
cucumber	0.89	0.93	0.91
curcuma	0.76	0.66	0.71
eggplant	0.78	0.80	0.79
galangal	0.77	0.67	0.72
ginger	0.68	0.64	0.66
guava	0.80	0.71	0.75
kale	0.68	0.70	0.69
longbeans	0.79	0.77	0.78
mango	0.60	0.52	0.56
melon	0.41	0.32	0.36
orange	0.69	0.86	0.76
paddy	0.68	0.80	0.74
papaya	0.86	0.67	0.75
peperchili	0.80	0.86	0.83
pineapple	0.96	0.87	0.91
pomelo	0.70	0.71	0.71
shallot	0.82	0.92	0.87
soybeans	0.66	0.66	0.66
spinach	0.75	0.77	0.76
sweetpotatoes	0.90	0.94	0.92
tobacco	0.66	0.67	0.67
waterapple	0.69	0.72	0.70
watermelon	0.74	0.93	0.83

Hasil evaluasi menunjukkan bahwa model EfficientNetB7 sangat efektif dalam mengklasifikasikan berbagai jenis tanaman dengan akurasi yang tinggi. Precision, recall, dan F1-score yang tinggi menunjukkan bahwa model tidak hanya akurat tetapi juga konsisten dalam mendeteksi kelas yang benar dengan tingkat kesalahan yang rendah.




Gambar 5. Evaluasi EfficientNetB7

Evaluasi model menunjukkan bahwa EfficientNetB7 adalah arsitektur yang sangat efektif untuk tugas klasifikasi tanaman. Dengan akurasi sebesar 85% dan metrik evaluasi lainnya yang juga tinggi, model ini dapat diandalkan untuk aplikasi praktis dalam identifikasi jenis tanaman, memberikan kontribusi signifikan bagi bidang pertanian, botani, dan riset ilmiah.

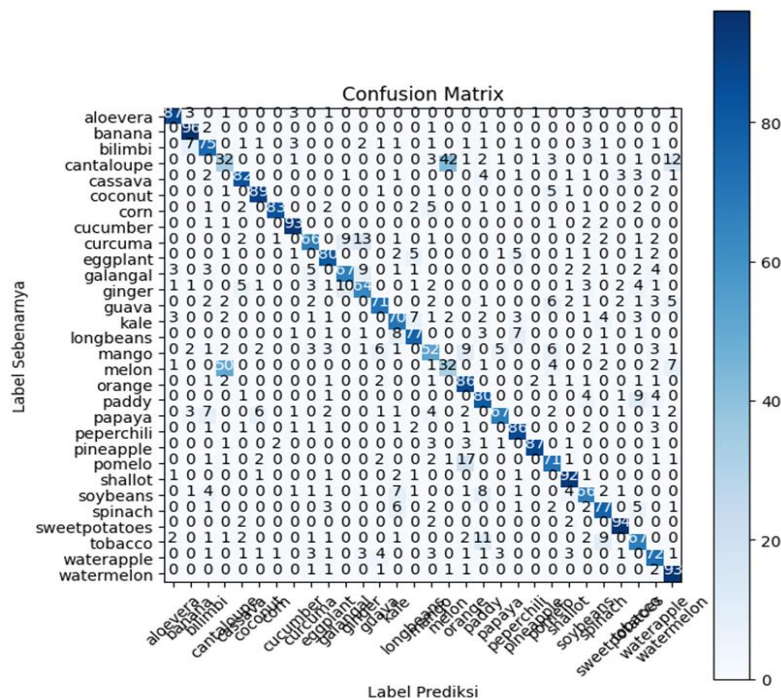
3.3.2 Confusion Matrix

Penggunaan confusion matrix bertujuan menyajikan informasi tentang prediksi yang dibuat oleh model dengan membandingkan dengan label yang benar dan data uji seperti ditunjukkan Gambar 7 dan 8.



Gambar 6. Confussion Matrix 4 Tanaman

Gambar 7 menunjukkan dalam pengujian mengalami beberapa error performa dan testing dengan hasil 385 prediksi benar dan 15 prediksi salah.



Gambar 7. Confussion Matrix 30 Tanaman

Gambar 8 dengan hasil 2254 prediksi benar dan 746 prediksi salah. Confusion Matrix memperlihatkan bahwa sebagian besar kesalahan klasifikasi terjadi pada kelas-kelas yang memiliki karakteristik visual yang mirip, yang merupakan area potensial untuk perbaikan lebih lanjut.

3.4 Hasil Prediksi

Dari kedua skenario prediksi yang telah diuji, model EfficientNetB7 menunjukkan kinerja yang baik dalam mengklasifikasikan berbagai jenis tanaman. Skenario prediksi otomatis memberikan gambaran tentang keandalan model dalam situasi di mana data uji telah disiapkan sebelumnya. Sementara itu, metode prediksi manual melalui



upload gambar menunjukkan fleksibilitas model dalam mengklasifikasikan gambar tanaman baru yang diunggah oleh pengguna. Kedua metode ini bersama-sama mengonfirmasi keefektifan model dalam aplikasi dunia nyata. Hasil evaluasi menunjukkan bahwa model yang dilatih memiliki performa yang cukup baik dalam mengklasifikasikan berbagai jenis tanaman. Namun, terdapat beberapa kesalahan dalam prediksi yang disebabkan oleh kemiripan karakteristik buah antar kelas.

Meskipun model memiliki kinerja yang baik secara umum, terdapat beberapa kasus kesalahan prediksi yang signifikan. Hal ini terutama terjadi pada buah-buahan yang memiliki kemiripan karakteristik, seperti melon dan cantaloupe, atau pomelo dan orange. Misalnya, model kadang-kadang salah mengklasifikasikan gambar melon sebagai cantaloupe, dan juga sebaliknya karena kemiripan warna dan bentuk.

4. KESIMPULAN

Penelitian berhasil menunjukkan bahwa penggunaan arsitektur EfficientNetB7 dalam pendekatan deep learning efektif untuk klasifikasi jenis tanaman. Melalui penggunaan teknik transfer learning, model yang dikembangkan mampu mencapai akurasi yang tinggi pada dua skenario klasifikasi yang berbeda, yaitu 4 tanaman dan 30 tanaman. Pada skenario pertama, model mencapai akurasi 97% dengan nilai loss sebesar 0.24, sementara pada skenario kedua, model mencapai akurasi 85% dengan nilai loss sebesar 1.1. Perbedaan nilai loss yang signifikan ini disebabkan oleh peningkatan jumlah tanaman yang menambah kompleksitas klasifikasi dan keragaman data yang lebih tinggi. Penelitian ini meskipun model menunjukkan performa yang sangat baik pada dataset dengan tanaman yang lebih sedikit, peningkatan jumlah tanaman mengakibatkan tantangan tambahan yang perlu diatasi, seperti overfitting dan underfitting. Evaluasi menggunakan metrik akurasi, precision, recall, F1-score dan Confusion Matrix menunjukkan bahwa model EfficientNetB7 dapat mengklasifikasikan tanaman dengan tingkat akurasi yang tinggi dan konsisten. Kontribusi penelitian ini terhadap bidang studi adalah memberikan bukti bahwa arsitektur EfficientNetB7, dengan penggunaan transfer learning, dapat secara efektif diterapkan untuk tugas-tugas klasifikasi yang kompleks dalam domain pertanian dan botani. Model ini menunjukkan potensi besar untuk digunakan dalam aplikasi praktis, seperti identifikasi tanaman di lapangan, yang dapat membantu meningkatkan efisiensi dan akurasi dalam pemeliharaan dan pengelolaan tanaman.

REFERENCES

- [1] Sigit Adinugroho and Yunita Arum Sari, *Implementasi Data Mining Menggunakan Weka, I.*, vol. I. Malang: UB Press, 2018.
- [2] B. Hariono, "Keragaman Morfologi Tanaman dan Tantangan Identifikasi.," *Jurnal Agrikultur*, vol. 5, no. 2, pp. 123–135, 2021.
- [3] T. Supriyadi, "Pengamatan Manual dalam Identifikasi Tanaman: Efektivitas dan Tantangannya," *Jurnal Ilmu Botani*, vol. 7, no. 3, pp. 50–65, 2023.
- [4] Dinas Pertanian, "Data Produktivitas dan Biaya Pemeliharaan Tanaman. Laporan Tahunan Dinas Pertanian.," Jakarta, 2024.
- [5] A. Wibowo, "Dampak Kesalahan Identifikasi Tanaman terhadap Penyebaran Penyakit Tanaman.," *Jurnal Fitopatologi Indonesia*, vol. 7, no. 3, pp. 245–258, 2021.
- [6] I. Ramadhanu, R. Susilo, and A. Wiryawan, "Deep Learning untuk Klasifikasi Citra Tanaman: Pendekatan dan Metode," *Jurnal Teknologi Pertanian*, vol. 9, no. 2, pp. 205–220, 2023.
- [7] M. Sandiwarno, "Convolutional Neural Network dalam Klasifikasi Citra: Studi Kasus pada Tanaman," *Jurnal Komputer dan Informatika*, vol. 12, no. 1, pp. 90–105, 2024.
- [8] S. Hartati and D. Nugroho, "Arsitektur EfficientNetB7 untuk Transfer Learning: Studi Kasus Klasifikasi Tanaman," *Jurnal Teknologi Informasi*, vol. 10, no. 3, pp. 301–315, 2022.
- [9] H. Srinidhi and R. Devi, "Penggunaan Spectral Clustering dan CNN untuk Klasifikasi Tanaman," *International Journal of Agricultural Sciences*, vol. 15, no. 4, pp. 345–357, 2020.
- [10] L. Rismyati, "Penggunaan Transfer Learning dengan EfficientNetB7 untuk Klasifikasi Kualitas Buah Salak," *Jurnal Hortikultura Indonesia*, vol. 11, no. 2, pp. 175–190, 2021.
- [11] Nguyen, "Pengembangan Model Klasifikasi Tiga Kelas untuk Lesi pada Retina Menggunakan Transfer Learning," *Jurnal Ilmu Kesehatan*, vol. 14, no. 1, pp. 88–100, 2023.
- [12] A. , & K. M. Faghihi, "Efektivitas Transfer Learning pada Diagnosis Kanker Kulit Menggunakan EfficientNetB7 dan EfficientNetB0," *Jurnal Teknologi Medis*, vol. 1, pp. 120–135, Sep. 2023.
- [13] A. Prayoga, Maimunah, P. Sukmasetya, Muhammad Resa Arif Yudianto, and Rofi Abul Hasani, "Arsitektur Convolutional Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta," *Journal of Applied Computer Science and Technology*, vol. 4, no. 2, pp. 82–89, Nov. 2023, doi: 10.52158/jacost.v4i2.486.
- [14] K. Kualitas Buah Salak dengan Transfer Learning Arsitektur VGG and A. Luthfiarta, "VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification," *Jurnal Informatika dan Teknologi Informasi*, vol. 18, no. 1, pp. 37–48, 2021, doi: 10.31515/telematika.v18i1.4025.
- [15] J. Marquis, "Plants Classification," 2023, Accessed: Jul. 05, 2024. [Online]. Available: <https://www.kaggle.com/datasets/marquis/plants-classification>
- [16] M. R. A. Yudianto, P. Sukmasetya, R. A. Hasani, and Maimunah, "Aspect-Based Sentiment Analysis of Borobudur Temple Reviews Use Support Vector Machine Algorithm," in *E3S Web of Conferences*, EDP Sciences, Mar. 2024. doi: 10.1051/e3sconf/202450001005.



- [17] B. Setiawan, A. Nugroho, and R. Utami, “Pendekatan Deep Learning untuk Identifikasi Jenis Tanaman,” *Jurnal Teknologi Pertanian*, vol. 14, no. 2, pp. 145–158, 2022.
- [18] D. Gonzalez, “Data Augmentation Techniques for Deep Learning,” *Journal of Machine Learning Research*, vol. 21, pp. 1–45, 2020.
- [19] B. Zoph, V. Vasudevan, J. Shlens, and Q. V. Le, “Learning Transferable Architectures for Scalable Image Recognition,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 8697–8710, 2018.