

# Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks

Seno Arnandito <sup>1\*</sup>, Theopilus Bayu Sasongko <sup>2\*</sup>

\* Informatika, Universitas AMIKOM Yogyakarta

[senoarnandito@students.amikom.ac.id](mailto:senoarnandito@students.amikom.ac.id) <sup>1</sup>, [theopilus.27@amikom.ac.id](mailto:theopilus.27@amikom.ac.id) <sup>2</sup>

## Article Info

### Article history:

Received 2024-06-24

Revised 2024-07-03

Accepted 2024-07-04

### Keyword:

*Efficientnetb7,*  
*Mobilenetv2,*  
*Convolutional Neural*  
*Networks,*  
*Herbal Plant Classification,*  
*Automatic Plant Recognition.*

## ABSTRACT

This study compares the performance of EfficientNetB7 and MobileNetV2 in classifying herbal plant species using Convolutional Neural Networks (CNNs). The primary objective was to automatically identify herbal plant species with high accuracy. Based on the evaluation results, both EfficientNetB7 and MobileNetV2 achieved approximately 98% accuracy in recognizing herbal plant species. While both models demonstrated excellent performance in precision, recall, and F1-score for most plant species, EfficientNetB7 showed a slight edge in some evaluation metrics. These findings provide valuable insights into the potential implementation of CNN architectures in automatic plant recognition applications, particularly for developing widely applicable web-based systems for herbal plant identification.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

## I. PENDAHULUAN

Pada era modern saat ini perkembangan teknologi dalam bidang kecerdasan buatan telah menghadirkan berbagai macam inovasi yang signifikan dalam berbagai aplikasi, seperti salah satunya adalah klasifikasi jenis tanaman herbal menggunakan algoritma Convolutional Neural Network (CNN). Tanaman herbal merupakan tanaman yang telah diidentifikasi oleh manusia dan diketahui memiliki senyawa senyawa yang bermanfaat dalam mencegah, menyembuhkan penyakit dan menjalankan fungsi fungsi biologis tertentu [1]. Mereka dapat ditemukan dengan mudah baik yang ditanam secara sengaja ataupun yang tumbuh secara alami. Masyarakat menggunakan tanaman herbal untuk membuat ramuan obat guna menyembuhkan berbagai macam penyakit [2]. Di Indonesia sendiri terdapat berbagai macam jenis tanaman herbal dengan khasiatnya yang berbeda beda seperti lidah buaya, daun kemangi, daun kunyit, daun teh, daun pepaya, daun sirih dll. Penggunaan obat tradisional dianggap lebih aman daripada penggunaan obat modern karena menggunakan tanaman herbal. Efek samping yang didapatkan oleh pengguna obat tradisional cenderung lebih rendah dibandingkan obat modern.

Identifikasi tanaman herbal memiliki kepentingan yang sangat besar dalam berbagai aspek, termasuk medis dan penelitian botani. Dalam keperluan medis, tanaman herbal

mengandung berbagai senyawa aktif yang dapat digunakan dalam pengembangan obat-obatan. Identifikasi yang akurat membantu memastikan penggunaan tanaman yang tepat untuk tujuan pengobatan, mengurangi risiko kesalahan identifikasi yang dapat menyebabkan efek samping yang tidak diinginkan. Dalam penelitian botani, identifikasi tanaman herbal membantu ilmuwan memahami keanekaragaman hayati, hubungan evolusi antar spesies, dan potensi penggunaan tanaman dalam berbagai bidang. Penelitian ini juga penting untuk konservasi tanaman herbal yang mungkin terancam punah. Namun, meskipun dianggap lebih aman, pengguna obat tradisional tetap perlu memperhatikan cara penggunaannya, ketepatan waktu konsumsi, dan ketepatan pemilihan obat. Mengidentifikasi tanaman herbal secara manual seringkali memakan waktu dan memerlukan pengetahuan botani yang mendalam. Karena tingkat penyimpanan memori manusia yang terbatas [3], sebagian besar masyarakat modern tidak mengetahui manfaat tanaman herbal. Oleh karena itu, dibuatlah sebuah program untuk mengidentifikasi jenis tanaman herbal secara otomatis dan cepat.

Penelitian menggunakan Neural Network Classification untuk mengidentifikasi jenis tanaman herbal telah menjadi topik yang menarik dan telah banyak dilakukan. Misalnya, penelitian yang dilakukan oleh [4] melakukan penelitian deteksi tanaman herbal di India dengan menggunakan dataset

1835 citra dan arsitektur VGG16, Xception, dan EfficientNetv2 berhasil mencapai akurasi test yang sangat tinggi, yaitu 99.55%, 99.99%, dan 99.46%, meskipun berpotensi mengalami overfitting. Kemudian penelitian yang dilakukan [5] juga telah melakukan percobaan untuk membuat model dalam identifikasi tanaman herbal dari bentuk daunnya menggunakan model VGG16 memperoleh akurasi pelatihan 81.61% dan validasi 90.74%, namun terdapat beberapa kesalahan identifikasi. Kemudian penelitian yang dilakukan oleh [6] menggunakan CNN dan framework TensorFlow untuk mendeteksi tanaman herbal sebagai obat penyakit kulit dan rambut mencapai akurasi 93%, tetapi terdapat kekeliruan dalam identifikasi daun tertentu. Selain itu, penelitian yang telah dilakukan oleh [7] telah berhasil membuat sebuah program pada platform android menggunakan metode waterfall dengan hasil akurasi sebesar 93% pada total keseluruhan datanya adalah 100 dengan masing masing tanaman terdapat 10 gambar kemudian hasilnya diuji pada black box. Dan penelitian yang dilakukan [8] mengenai deteksi kelayakan ban menggunakan berbagai arsitektur CNN menemukan bahwa DenseNet-121 memberikan performa terbaik dengan akurasi 92.62%, diikuti oleh MobileNetV2, InceptionV3, dan ResNet-50. Dari penelitian-penelitian tersebut, masih terdapat celah untuk melakukan penelitian lebih jauh. Misalnya, tantangan seperti overfitting dan kesalahan identifikasi masih perlu diatasi. Penggunaan dataset yang lebih besar dan lebih bervariasi dapat membantu meningkatkan keandalan model. Selain itu, eksplorasi arsitektur CNN yang lebih baru atau kombinasi berbagai arsitektur mungkin dapat memberikan hasil yang lebih baik.

Metode yang akan digunakan dalam penelitian ini adalah algoritma Convolutional Neural Network (CNN), yang memiliki pendekatan kuat dalam pengolahan citra, terutama dalam klasifikasi. Dua arsitektur CNN yang dipilih adalah EfficientNetB7 dan MobileNetV2. EfficientNetB7 memprioritaskan efisiensi komputasi dengan meningkatkan skala secara proporsional untuk meningkatkan kinerja dengan jumlah parameter yang relatif sedikit, meskipun menghasilkan model dengan ukuran sangat besar. Sementara itu, MobileNetV2 dirancang untuk perangkat mobile sehingga menghasilkan model dengan ukuran kecil, menggunakan separable convolution untuk mengurangi beban komputasi tanpa mengorbankan kinerja. Pemilihan dua arsitektur tersebut didasarkan pada kecepatan, akurasi, ukuran model, dan ketersediaan sumber daya.

Pemilihan EfficientNetB7 dan MobileNetV2 sebagai model yang dibandingkan dalam penelitian ini didasarkan pada beberapa alasan penting. Pertama, dari segi efisiensi dan kinerja, EfficientNetB7 terkenal karena kemampuannya menggabungkan efisiensi komputasi dan kinerja tinggi melalui teknik scaling yang baik, menghasilkan model dengan jumlah parameter yang relatif sedikit tetapi dengan ukuran besar. Sementara itu, MobileNetV2, yang dirancang khusus untuk perangkat mobile, mengutamakan efisiensi dan kecepatan komputasi melalui penggunaan teknik separable

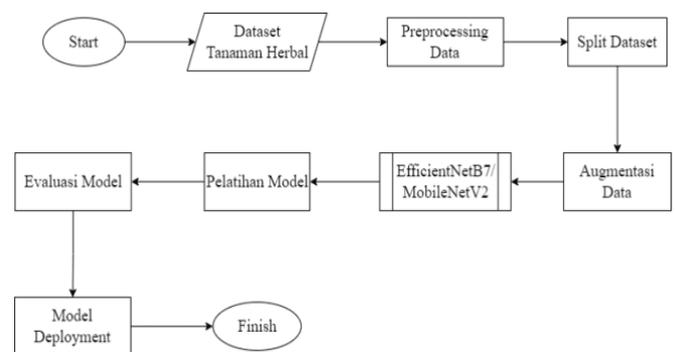
convolution. Kedua, dari segi perbandingan ukuran model, EfficientNetB7 menawarkan kesempatan untuk mengeksplorasi peningkatan performa melalui peningkatan ukuran model, sedangkan MobileNetV2 memungkinkan eksplorasi performa model yang lebih ringan dan efisien dalam penggunaan sumber daya komputasi. Ketiga, dari segi kecepatan dan sumber daya komputasi, EfficientNetB7 menawarkan kinerja tinggi yang mungkin memerlukan sumber daya komputasi lebih besar, sementara MobileNetV2 menawarkan kecepatan dan efisiensi lebih baik dengan sumber daya yang lebih sedikit.

Penelitian ini bertujuan untuk mengembangkan program untuk mendeteksi jenis tanaman herbal dan membandingkan kinerja arsitektur EfficientNetB7 dan MobileNetV2 pada dataset tanaman herbal di Indonesia, serta untuk menentukan arsitektur yang paling baik dalam hal akurasi dan efisiensi komputasi. Hasil penelitian akan diterapkan ke dalam program pendeteksi jenis tanaman herbal berbasis website lokal untuk identifikasi tanaman herbal. Penelitian juga akan membandingkan kedua arsitektur dalam hal akurasi dan kebutuhan sumber daya komputasi, serta mengungkap kelebihan dan kelemahan masing-masing dalam klasifikasi tanaman herbal.

## II. METODE

### A. Tahapan Penelitian

Dalam melakukan metode penelitian terdapat beberapa tahapan yang dilakukan seperti pengumpulan dataset tanaman herbal, preprocessing data, split dataset, augmentasi data, konfigurasi arsitektur EfficientNetB7 dan MobileNetV2 untuk dijadikan perbandingan, pelatihan model, evaluasi model dan model deployment. Rancangan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

### B. Dataset Tanaman Herbal

Dataset yang digunakan pada penelitian ini adalah data citra yang bersifat publik. Data citra yang digunakan bisa diperoleh dari website Kaggle [9] yang berisi 10 folder jenis tanaman herbal di Indonesia yang masing masingnya memiliki 100 citra dengan total keseluruhan terdapat 1000 citra data, untuk lebih jelasnya bisa dilihat pada Tabel 1.

TABEL I  
JENIS JENIS TANAMAN HERBAL

No	Nama Tanaman Herbal	Jumlah Image
1	Daun Jambu Biji	100
2	Daun Kari	100
3	Daun Kemangi	100
4	Daun Kunyit	100
5	Daun Mint	100
6	Daun Pepaya	100
7	Daun Sirih	100
8	Daun Sirsak	100
9	Lidah Buaya	100
10	Teh Hijau	100
TOTAL		1000

Dataset ini disimpan di Google Drive dan akan diimpor ke dalam Google Colab untuk digunakan dalam penelitian. Setiap citra dalam dataset ini memiliki resolusi yang bervariasi dan merupakan representasi dari berbagai jenis tanaman herbal yang umum ditemukan di Indonesia. Karakteristik dataset ini mencakup variasi dalam bentuk, warna, dan tekstur daun dari setiap jenis tanaman herbal, tetapi variasi background gambar yang terbatas menambah tantangan dalam pengembangan model yang baik dalam identifikasi jenis tanaman herbal. Oleh karena itu, penting untuk melakukan augmentasi untuk meningkatkan generalisasi model dalam situasi nyata. Sample gambar jenis tanaman herbal bisa dilihat pada Gambar 2.



Gambar 2. Sample gambar jenis tanaman herbal

C. Preprocessing Data

Dalam penelitian ini, langkah awal adalah melakukan instalasi library EfficientNet di Google Colab dan mengimpor model EfficientNetB7 serta MobileNetV2, bersama dengan library lain yang dibutuhkan seperti TensorFlow dan OpenCV. Selanjutnya, dibuat sebuah fungsi yang akan memberikan label pada setiap gambar berdasarkan nama folder di mana gambar tersebut disimpan, sehingga setiap citra dapat diidentifikasi dengan jenis tanaman herbal yang sesuai. Proses ini melibatkan penggunaan looping untuk memberikan label kepada setiap gambar berdasarkan struktur folder yang telah ditentukan. Setelah itu, dilakukan normalisasi data dengan mengubah nilai piksel citra menjadi

rentang antara 0 hingga 1, sehingga memudahkan proses pelatihan model. Selain itu, label kategori tanaman herbal dienkoding menggunakan LabelEncoder() dan dikonversi menjadi format one-hot encoded vectors menggunakan to\_categorical(), yang penting untuk persiapan data sebelum diberikan ke dalam model untuk dilatih.

D. Split Dataset

Membagi dataset menjadi data pelatihan, data validasi dan data uji, sebelum itu data dimasukkan kedalam variabel data sementara dengan rasio 70:30. Selanjutnya, data sementara tersebut dibagi kembali menjadi data validasi dan data uji dengan rasio 50:50, maka hasil akhirnya akan ada 70% data pada data pelatihan, 15% pada data uji dan 15% pada data validasi.

E. Augmentasi Data

Terdapat beberapa teknik penting dalam augmentasi data yang digunakan untuk meningkatkan kualitas model Machine Learning, terutama dalam pengenalan citra seperti identifikasi jenis tanaman herbal menggunakan Convolutional Neural Network (CNN). Pertama, rotasi digunakan untuk mengubah sudut pandang citra hingga 20 derajat, memungkinkan model mempelajari variasi posisi objek dalam citra. Selanjutnya, zoom dengan rentang 20% digunakan untuk memperbesar atau memperkecil citra, mengajarkan model untuk mengenali objek dengan ukuran yang bervariasi. Pergeseran horizontal dan vertikal hingga 20% dari dimensi aslinya membantu dalam memvariasikan posisi objek dalam citra. Flip horizontal memungkinkan model untuk memahami objek dari sisi yang berbeda, sementara transformasi shear memperkenalkan variasi geometri. Penggunaan fill mode diterapkan untuk menangani area kosong yang muncul setelah transformasi, memastikan citra yang dihasilkan tetap baik untuk digunakan. Dengan menerapkan augmentasi data ini, model CNN dapat belajar dari berbagai variasi citra tanaman herbal, meningkatkan kemampuan untuk menggeneralisasi dan menghasilkan prediksi yang lebih akurat ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya. Selanjutnya hasil augmentasi di tampilkan agar bisa dilihat hasilnya.



Gambar 3. Hasil Augmentasi

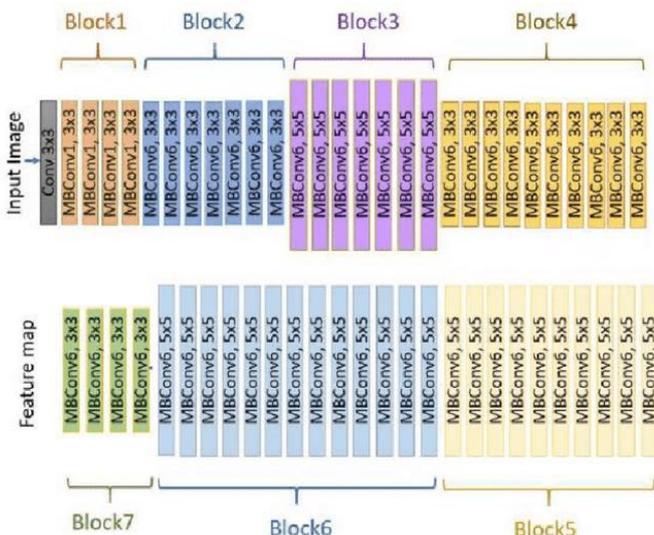
F. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah metode yang umum digunakan dalam Deep Learning untuk mendeteksi dan mengenali objek dalam gambar digital. CNN menerima gambar sebagai input dan memprosesnya melalui serangkaian lapisan konvolusi, pooling, dan lapisan tersembunyi, yang memungkinkan CNN mempelajari representasi fitur signifikan dalam gambar. Dengan demikian, CNN dapat secara efektif mengekstraksi informasi penting yang ada dalam gambar [10].

CNN terdiri dari lapisan-lapisan dengan susunan neuron tiga dimensi. Lapisan-lapisan ini termasuk lapisan konvolusi, pooling, normalisasi, fully connected, dan loss, yang semuanya digunakan dalam pemrosesan. Lapisan konvolusi mengekstraksi fitur lokal, lapisan pooling mengurangi dimensi spasial, lapisan normalisasi memperkuat respons penting, lapisan fully connected menghubungkan neuron antar lapisan, dan lapisan loss menghitung kesalahan prediksi. Melalui lapisan-lapisan ini, CNN dapat mempelajari fitur-fitur penting dan melakukan pengenalan objek dengan akurasi tinggi. Setiap lapisan memiliki peran penting dalam ekstraksi fitur dan pembelajaran pola pada data gambar. Dengan kombinasi pemrosesan berurutan, CNN mampu mencapai performa yang baik dalam tugas klasifikasi dan deteksi gambar [11].

G. EfficientNetB7 dan MobileNetV2

Setelah dilakukan augmentasi, pada tahap ini dilakukan konfigurasi model serta menjalankan EfficientNetB7 dan MobileNetV2.

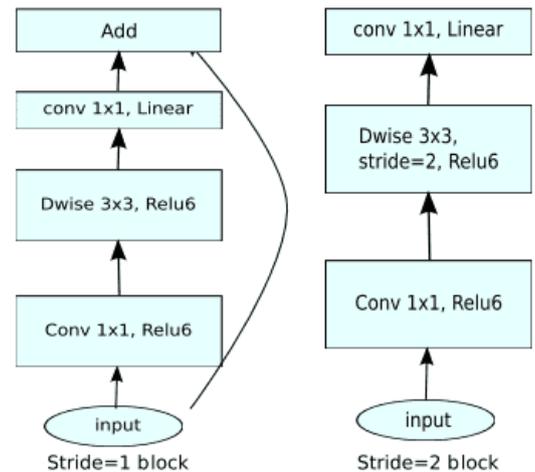


Gambar 4. Arsitektur EfficientNetB7 [13]

EfficientNet sendiri merupakan salah satu arsitektur transfer learning pada algoritma CNN yang dikembangkan oleh Google pada tahun 2019 lalu [12], saat ini, EfficientNet terdiri dari 8 model yang berbeda, yaitu EfficientNetB0 hingga EfficientNetB7, yang memiliki jumlah parameter yang bertambah dari 5,3 juta hingga 66 juta parameter, dengan

tingkat akurasi yang meningkat seiring dengan peningkatan jumlah parameter, pada Gbr. 4. adalah arsitektur dari EfficientNetB7.

Selanjutnya MobileNetV2 merupakan sebuah jenis arsitektur Convolutional Neural Network (CNN) yang didesain khusus untuk perangkat mobile, yang bertujuan untuk mengurangi kebutuhan akan sumber daya komputasi. Arsitektur ini merupakan penyempurnaan dari pendahulunya, MobileNet. Perbedaan utama antara MobileNet dan arsitektur CNN konvensional terletak pada pendekatan dalam penggunaan lapisan konvolusi atau convolution layer [14].



Gambar 5. Arsitektur MobileNetV2 [15]

H. Pelatihan Model

Dua model, yakni EfficientNetB7 dan MobileNetV2, digunakan dalam pelatihan. Model dasar EfficientNetB7 dan MobileNetV2 diinisialisasi dengan bobot dari pre-trained model ImageNet dan lapisan paling atasnya dihilangkan (include\_top=False). Pada awalnya, sebagian besar lapisan tidak dapat dilatih ulang dengan mengatur trainable=False untuk lapisan-lapisan tersebut, kecuali 20 lapisan terakhir yang tetap dilatih. Struktur model tambahan terdiri dari GlobalAveragePooling2D untuk mengurangi dimensi data, lapisan Dense yang mengandung 256 neuron dengan fungsi aktivasi ReLU, dilanjutkan dengan BatchNormalization dan Dropout untuk mengurangi overfitting, dan lapisan Dense terakhir yang mengeluarkan probabilitas kelas menggunakan softmax activation, sesuai dengan jumlah kelas (jumlah jenis tanaman herbal dalam dataset). Untuk mengurangi overfitting, regularisasi L2 diterapkan pada lapisan-lapisan Conv2D dan Dense dengan weight\_decay=1e-4. Optimizer yang digunakan adalah Adam dengan learning rate yang dijadwalkan secara eksponensial mengikuti jadwal ExponentialDecay. Parameter decay\_steps dan decay\_rate digunakan untuk mengatur penurunan learning rate secara bertahap selama pelatihan. Model dikompilasi dengan fungsi loss categorical\_crossentropy untuk tugas klasifikasi multikelas dan menggunakan metrik akurasi untuk mengukur performa selama pelatihan.

### I. Evaluasi Model

Evaluasi model dilakukan dengan beberapa metode. Pertama, model dievaluasi pada data validasi untuk memantau kemajuan selama pelatihan. Callback EarlyStopping digunakan untuk menghentikan pelatihan jika tidak ada peningkatan pada metrik validasi (misalnya, loss) setelah beberapa epoch berturut-turut (dalam hal ini, diatur patience=10). Callback ReduceLRonPlateau mengurangi learning rate secara otomatis ketika tidak ada peningkatan pada metrik validasi dalam beberapa epoch (diatur dengan faktor pengurangan dan nilai minimum learning rate). Setelah pelatihan selesai, model dievaluasi pada data uji yang belum pernah dilihat sebelumnya. Evaluasi mencakup perhitungan metrik seperti akurasi, precision, recall, dan F1-score untuk mengevaluasi performa klasifikasi model terhadap setiap kelas tanaman herbal. Confusion matrix juga digunakan untuk visualisasi jumlah prediksi yang benar dan salah untuk setiap kelas. Untuk perhitungan matematikanya bisa dilihat pada persamaan berikut.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

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

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

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

Di mana:

- TP: True Positives (benar positif)
- TN: True Negatives (benar negatif)
- FP: False Positives (positif salah)
- FN: False Negatives (negatif salah)

Grafik akurasi dan loss selama pelatihan juga ditampilkan untuk memberikan gambaran visual tentang bagaimana model berkinerja seiring berjalannya epoch.

### J. Model Deployment

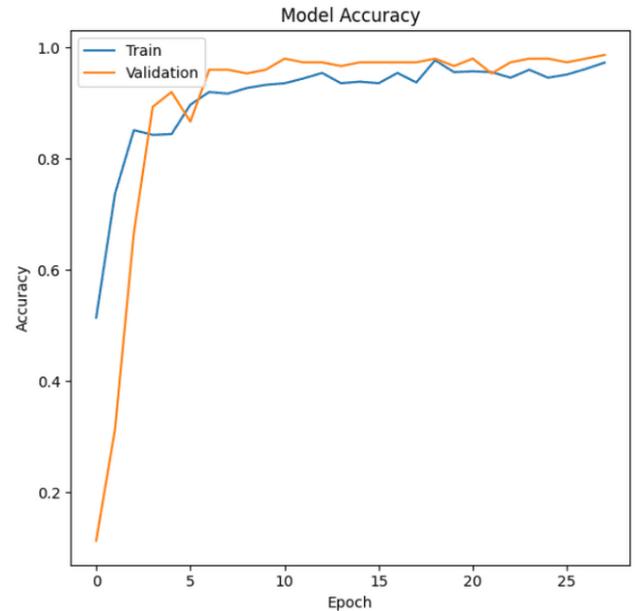
Tahapan selanjutnya model model yang telah berhasil dibuat akan digunakan dalam program berbasis website lokal menggunakan library flask untuk mendeteksi jenis tanaman herbal dan untuk melihat model mana dari hasil training kedua arsitektur EfficientNetB7 dan MobileNetV2 yang memiliki tingkat akurasi dalam mengidentifikasi jenis tanaman herbal yang paling tinggi.

## III. HASIL DAN PEMBAHASAN

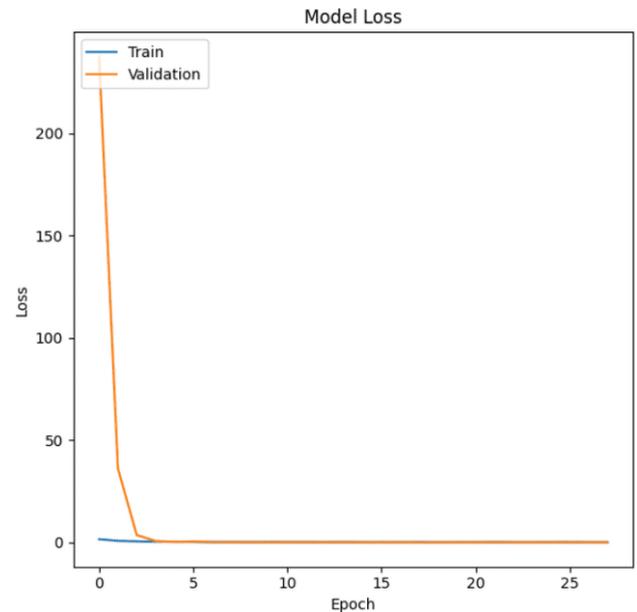
### A. Model EfficientNetB7

Model EfficientNetB7 digunakan untuk mendeteksi berbagai jenis tanaman herbal di Indonesia. Setelah model dilatih, hasilnya disajikan melalui grafik training akurasi dan loss, metrik evaluasi serta confusion matrix yang akan

digunakan sebagai perbandingan model mana yang memiliki kinerja dan hasil yang paling baik.



Gambar 6. Grafik Akurasi EfficientNetB7



Gambar 7. Grafik Loss EfficientNetB7

#### 1) Model Accuracy

- Train: Kurva akurasi pada data pelatihan meningkat tajam pada beberapa epoch pertama dan mencapai nilai yang mendekati 1.0 pada sekitar epoch ke-10, kemudian stabil di sekitar nilai tersebut hingga akhir pelatihan.
- Validation: Kurva akurasi pada data validasi juga meningkat tajam pada awal pelatihan dan mencapai nilai yang mendekati 1.0 pada sekitar epoch ke-10. Kurva ini

kemudian stabil dengan sedikit fluktuasi, tetapi tetap tinggi dan konsisten dengan kurva akurasi pelatihan.

2) Model Loss

- Train: Kurva loss pada data pelatihan menunjukkan penurunan tajam pada beberapa epoch pertama dan kemudian stabil pada nilai yang sangat rendah, hampir mendekati 0, dari sekitar epoch ke-5 hingga akhir pelatihan.
- Validation: Kurva loss pada data validasi juga menunjukkan penurunan tajam pada beberapa epoch pertama, kemudian stabil pada nilai yang rendah tetapi sedikit lebih tinggi dibandingkan kurva loss pelatihan. Kurva ini tetap stabil hingga akhir pelatihan dengan nilai yang sangat rendah.

Grafik berhenti secara otomatis menggunakan callbacks karena pada epoch ke 28 tidak ada perubahan performa kemudian pada grafik juga ditunjukkan bahwa model EfficientNetB7 memiliki performa yang sangat baik dengan akurasi tinggi dan loss rendah baik pada data pelatihan maupun validasi. Kurva yang stabil dan konsisten menunjukkan bahwa model ini tidak overfitting dan memiliki generalisasi yang baik.

TABEL II  
HASIL EVALUASI MODEL EFFICIENTNETB7

Metriks	Nilai
Akurasi	98.00%
Precision	98.11%
Recall	98.00%
F1 Score	98.00%

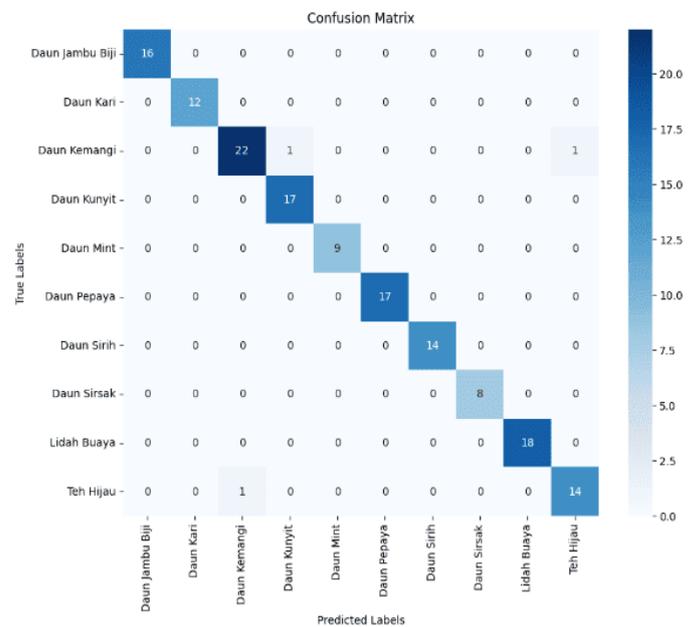
Pada Tabel II, akurasi model EfficientNetB7 mencapai 98.00%, dengan precision sebesar 98.11%, recall sebesar 98.00%, dan F1 score sebesar 98.00%. Hasil ini menunjukkan bahwa model EfficientNetB7 memiliki performa yang sangat baik dalam mendeteksi berbagai jenis daun. Untuk lebih detailnya pada masing masing jenis tanaman herbal bisa dilihat pada Tabel III.

TABEL III  
DETAIL PERFORMA MASING MASING KELAS

Kelas	Precision	Recall	F1 Score	Support
Daun Jambu Biji	1.00	1.00	1.00	16
Daun Kari	1.00	1.00	1.00	12
Daun Kemangi	0.96	0.92	0.94	24
Daun Kunyit	0.94	1.00	0.97	17
Daun Mint	1.00	1.00	1.00	9
Daun Pepaya	1.00	1.00	1.00	17
Daun Sirih	1.00	1.00	1.00	14
Daun Sirsak	1.00	1.00	1.00	8
Lidah Buaya	1.00	1.00	1.00	18
Teh Hijau	0.93	0.93	0.93	15

Berdasarkan hasil evaluasi, model menunjukkan performa yang sangat baik dalam mengklasifikasikan berbagai jenis daun. Untuk daun jambu biji dan daun kari, model mencapai precision, recall, dan f1-score sempurna sebesar 1.00,

menunjukkan bahwa semua sampel untuk kedua jenis daun ini diklasifikasikan dengan benar tanpa kesalahan. Pada daun kemangi, precision tercatat sebesar 0.96 dan recall 0.92, menghasilkan f1-score 0.94, yang menunjukkan beberapa kesalahan dalam klasifikasi namun tetap dalam batas yang dapat diterima. Daun kunyit juga menunjukkan performa yang baik dengan precision 0.94 dan recall 1.00, menghasilkan f1-score 0.97. Daun mint, daun pepaya, daun sirih, dan daun sirsak semuanya memiliki metrik evaluasi sempurna dengan nilai 1.00, menandakan bahwa model ini sangat efektif dalam mengklasifikasikan sampel-sampel tersebut. Sementara itu, daun lidah buaya dan teh hijau menunjukkan performa yang sedikit lebih rendah tetapi masih tinggi, dengan f1-score masing-masing 1.00 dan 0.93. Secara keseluruhan, model menunjukkan kemampuan klasifikasi yang sangat baik dengan hanya beberapa kesalahan kecil pada beberapa jenis daun.

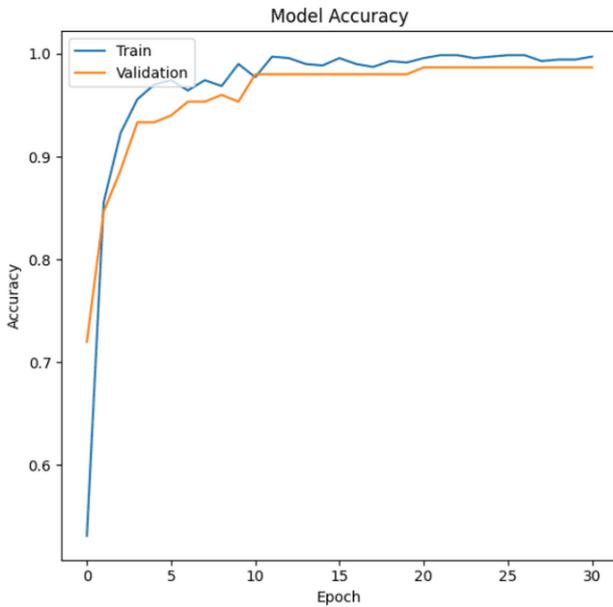


Gambar 8. Confusion Matrix EfficientNetB7

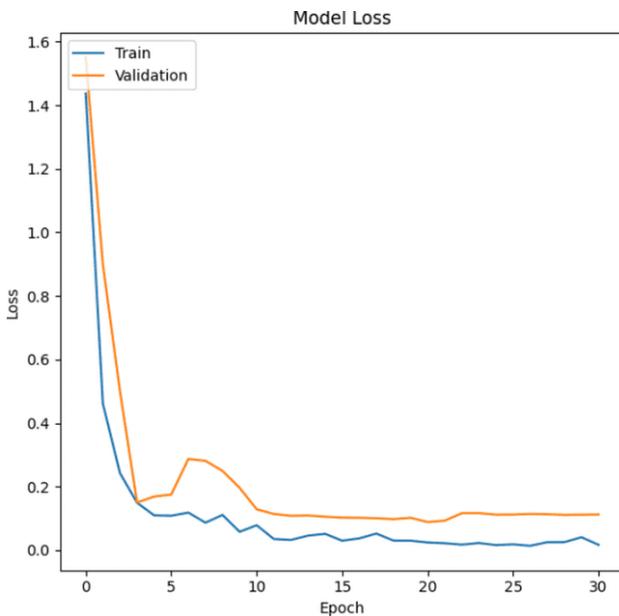
Confusion Matrix yang ditunjukkan diatas memberikan gambaran mengenai performa model dalam mengklasifikasikan berbagai jenis tanaman herbal dengan tingkat akurasi yang tinggi. Matriks ini menunjukkan bahwa model mampu mengklasifikasikan semua instance dari Daun Jambu Biji, Daun Kari, Daun Mint, Daun Pepaya, Daun Sirih, Daun Sirsak dan Lidah buaya dengan benar tanpa kesalahan. Ini ditunjukkan oleh angka yang tinggi pada diagonal utama pada matriks. Namun, terdapat sedikit kesalahan klasifikasi pada Daun Kemangi, Daun Kunyit dan Teh Hijau, dimana satu Daun Kunyit diklasifikasikan sebagai Daun Kemangi dan satu instance Teh Hijau diklasifikasikan sebagai Daun Kemangi. Kesalahan ini menunjukkan bahwa model mungkin mengalami sedikit kebingungan dalam membedakan antara ketiga jenis daun tersebut.

**B. Model MobileNetV2**

Selanjutnya pada model *MobileNetV2* juga digunakan untuk mendeteksi berbagai jenis tanaman herbal di Indonesia. Setelah model dilatih, hasilnya disajikan melalui grafik training akurasi dan loss, metrik evaluasi serta confusion matrix yang akan digunakan sebagai perbandingan model mana yang memiliki kinerja dan hasil yang paling baik



Gambar 9. Grafik Akurasi MobileNetV2



Gambar 10. Grafik Loss MobileNetV2

**1) Model Accuracy**

- Train: Kurva akurasi pada data pelatihan meningkat tajam pada beberapa epoch pertama dan mencapai nilai yang mendekati 1.0 pada sekitar epoch ke-10, kemudian stabil di sekitar nilai tersebut hingga akhir pelatihan.

- Validation: Kurva akurasi pada data validasi juga meningkat tajam pada awal pelatihan dan mencapai nilai yang mendekati 1.0 pada sekitar epoch ke-10. Kurva ini kemudian stabil dengan sedikit fluktuasi, tetapi tetap tinggi dan konsisten dengan kurva akurasi pelatihan.

**2) Model Loss**

- Train: Kurva loss pada data pelatihan menunjukkan penurunan tajam pada beberapa epoch pertama dan kemudian stabil pada nilai yang sangat rendah, hampir mendekati 0, dari sekitar epoch ke-10 hingga akhir pelatihan.
- Validation: Kurva loss pada data validasi menunjukkan penurunan tajam pada beberapa epoch pertama, kemudian stabil pada nilai yang rendah tetapi sedikit lebih tinggi dan lebih fluktuatif dibandingkan kurva loss pelatihan. Kurva ini tetap stabil hingga akhir pelatihan dengan nilai yang cukup rendah.

Grafik menunjukkan bahwa model *MobileNetV2* memiliki performa yang sangat baik dengan akurasi tinggi dan loss rendah baik pada data pelatihan maupun validasi. Meskipun kurva akurasi dan loss sedikit lebih fluktuatif dibandingkan dengan *EfficientNetB7*, model ini tetap menunjukkan performa yang baik dan tidak overfitting secara signifikan.

TABEL IV  
HASIL EVALUASI MODEL MOBILENETV2

Metriks	Nilai
Akurasi	98.00%
Precision	98.14%
Recall	98.00%
F1 Score	97.92%

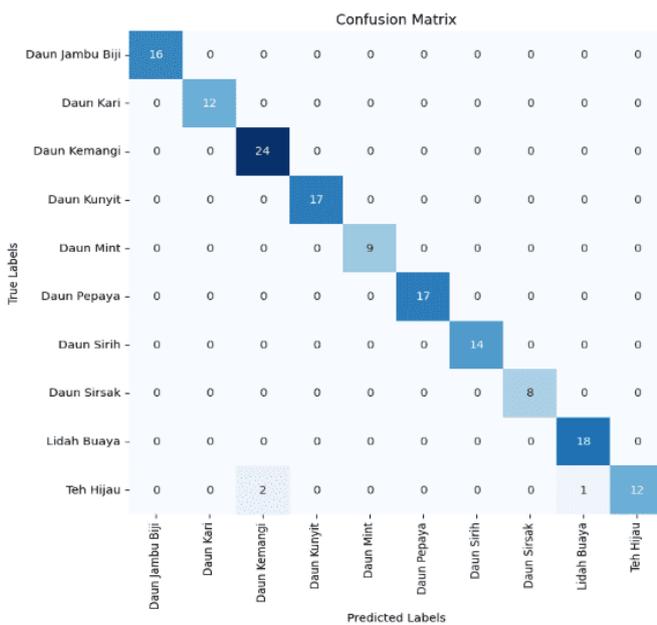
Model klasifikasi daun yang dihasilkan menunjukkan performa yang sangat baik dengan nilai metrik yang tinggi. Akurasi model mencapai 98%, yang berarti model dapat mengklasifikasikan 98% dari data uji dengan benar. Precision sebesar 98.14% menunjukkan bahwa dari semua prediksi positif yang dibuat oleh model, 98.14% di antaranya adalah benar-benar positif. Recall sebesar 98% menunjukkan bahwa dari semua sampel positif yang ada dalam data uji, model berhasil menemukan 98% di antaranya. F1 Score sebesar 97.92%, yang merupakan rata-rata harmonis dari precision dan recall, mengindikasikan keseimbangan yang baik antara kedua metrik tersebut. Hasil ini menunjukkan bahwa model memiliki kinerja yang sangat baik dalam mengklasifikasikan berbagai jenis daun, dengan kesalahan yang minimal. Untuk lebih detailnya pada masing masing jenis tanaman herbal bisa dilihat pada Tabel V.

Model klasifikasi daun menunjukkan performa yang sangat baik dengan rata-rata precision, recall, dan f1-score yang hampir sempurna pada sebagian besar kategori daun. Kategori seperti Daun Jambu Biji, Daun Kari, Daun Kunyit, Daun Mint, Daun Pepaya, Daun Sirih, dan Daun Sirsak memiliki nilai precision, recall, dan f1-score sebesar 1.00, menunjukkan klasifikasi yang sempurna. Daun Kemangi

memiliki f1-score 0.96, sementara Lidah Buaya memiliki f1-score 0.97, menunjukkan performa yang sangat baik dengan sedikit kesalahan. Kategori Teh Hijau memiliki f1-score 0.89, menunjukkan beberapa kesalahan dalam mendeteksi sampel positif. Secara keseluruhan, model ini sangat efektif dalam mengklasifikasikan sebagian besar jenis daun dengan akurasi tinggi.

TABEL V  
DETAIL PERFORMA MASING MASING KELAS

Kelas	Precision	Recall	F1 Score	Support
Daun Jambu Biji	1.00	1.00	1.00	16
Daun Kari	1.00	1.00	1.00	12
Daun Kemangi	0.92	1.00	0.96	24
Daun Kunyit	1.00	1.00	1.00	17
Daun Mint	1.00	1.00	1.00	9
Daun Pepaya	1.00	1.00	1.00	17
Daun Sirih	1.00	1.00	1.00	14
Daun Sirsak	1.00	1.00	1.00	8
Lidah Buaya	0.95	0.80	0.89	18
Teh Hijau	1.00	0.80	0.89	15



Gambar 11. Confusion Matrix MobileNetV2

Confusion Matrix menunjukkan performa model dalam mengklasifikasikan berbagai jenis daun. Model berhasil mengklasifikasikan sebagian besar sampel dengan benar, seperti yang terlihat pada diagonal utama dengan nilai yang tinggi. Semua kategori daun, kecuali Teh Hijau, menunjukkan hasil klasifikasi yang sempurna tanpa kesalahan. Teh Hijau mengalami beberapa kesalahan, dengan 2 sampel salah diklasifikasikan sebagai Lidah Buaya. Secara keseluruhan, matriks ini menunjukkan bahwa model sangat efektif dalam mengklasifikasikan sebagian besar jenis daun dengan hanya sedikit kesalahan pada beberapa kategori.

C. Perbandingan Hasil

1) Perbandingan Performa Model

Perbandingan hasil dari kedua model ini memberikan beberapa insight penting mengenai keunggulan dan kelemahan masing-masing model dan hasil prediksi model. Tabel VI menunjukkan perbandingan performa antara EfficientNetB7 dan MobileNetV2 dalam beberapa metrik evaluasi.

TABEL IV  
HASIL EVALUASI MODEL

Metriks	EfficientNetB7	MobileNetV2
Akurasi	98.00%	98.00%
Precision	98.11%	98.14%
Recall	98.00%	98.00%
F1 Score	98.00%	97.92%

2) Keunggulan dan Kelemahan

• EfficientNetB7:

**Keunggulan:** EfficientNetB7 menunjukkan keunggulan dalam beberapa metrik evaluasi karena arsitektur yang unik dan disesuaikan secara optimal. Arsitektur ini mengintegrasikan konsep Compound Scaling yang memungkinkan untuk pencarian ukuran model (width, depth, resolution) yang optimal, sesuai dengan kompleksitas dan variasi dalam data tanaman herbal yang kompleks. Dibandingkan dengan MobileNetV2 yang lebih ringan, EfficientNetB7 memiliki kapasitas yang lebih besar dan jumlah parameter yang lebih tinggi, memungkinkan untuk representasi fitur yang lebih baik dari gambar-gambar tanaman herbal dengan variasi signifikan dalam tekstur, warna, dan ukuran. Hal ini menghasilkan performa yang superior dalam akurasi, precision, recall, dan F1-score, menunjukkan kemampuan model untuk mengenali dan mengklasifikasikan jenis-jenis daun dengan tingkat kesalahan yang minimal.

**Kelemahan:** Meskipun memiliki performa yang unggul, EfficientNetB7 membutuhkan waktu pelatihan yang lebih lama dan memerlukan sumber daya komputasi yang lebih besar. Hal ini bisa menjadi hambatan dalam aplikasi yang memerlukan kecepatan dan efisiensi komputasi.

• MobileNetV2:

**Keunggulan:** MobileNetV2 lebih cepat dalam proses pelatihan dan lebih efisien dalam penggunaan sumber daya komputasi. Precision MobileNetV2 sedikit lebih tinggi dibandingkan dengan EfficientNetB7. Model ini cocok untuk aplikasi yang memerlukan solusi cepat dan efisien, serta dapat berjalan pada perangkat dengan kemampuan komputasi terbatas.

**Kelemahan:** Meskipun performa akurasi dan recall sama dengan EfficientNetB7, MobileNetV2 memiliki F1 Score yang sedikit lebih rendah. Hal ini menunjukkan bahwa model ini mungkin sedikit kurang andal dalam beberapa kasus klasifikasi yang kompleks, meskipun tetap memiliki kinerja yang cukup baik secara keseluruhan.

3) Hasil Prediksi Model

• EfficientNetB7:



Gambar 12. Hasil Prediksi EfficientNetB7

Gambar di atas menunjukkan daun tanaman herbal dengan hasil prediksi model menggunakan hasil training pada variabel train dengan test yang sudah dibuat sebelumnya. Setiap kotak berisi gambar daun dengan label asli ("True") dan prediksi model ("Pred"). Dari gambar-gambar ini, terlihat bahwa model melakukan beberapa prediksi dengan benar, seperti "Daun Pepaya" dan "Daun Sirsak". Namun, ada juga kesalahan, misalnya, "Daun Kunyit" diprediksi sebagai "Daun Kemangi" dan "Daun Sirih" diprediksi sebagai "Daun Kari". Kesalahan ini menunjukkan bahwa meskipun model sudah cukup baik, masih ada ruang untuk perbaikan dalam mengidentifikasi beberapa jenis daun yang memiliki bentuk dan warna yang mirip.

• MobileNetV2:



Gambar 13. Hasil Prediksi MobileNetV2

Gambar di atas menunjukkan daun tanaman herbal dengan hasil prediksi model menggunakan hasil training pada variabel train dengan test yang sudah dibuat sebelumnya. Setiap kotak berisi gambar daun dengan label asli ("True") dan prediksi model ("Pred"). Model menunjukkan kinerja yang baik dengan beberapa prediksi yang benar seperti "Daun Pepaya", "Daun Sirsak", "Teh Hijau", "Daun Kari", dan "Daun Sirih". Kesalahan prediksi tidak ditemukan pada contoh-contoh di gambar ini, menunjukkan bahwa model tersebut bekerja dengan sangat baik dalam mengenali jenis-jenis daun yang berbeda yang ditampilkan.

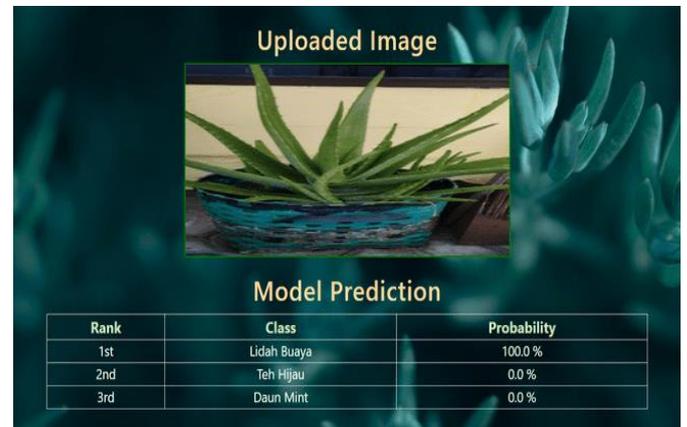
D. Deployment Model

Setelah model dibuat dan di evaluasi hasil akhirnya antara arsitektur EfficientNetB7 dan MobileNetV2 untuk dilihat model mana yang memiliki hasil paling baik. Peneliti memutuskan untuk menggunakan model yang dihasilkan dari arsitektur EfficientNetB7 untuk digunakan dalam program deployment pendeteksi jenis tanaman herbal menggunakan library flask berbasis website lokal. Berikut merupakan tampilan dan hasil programnya.

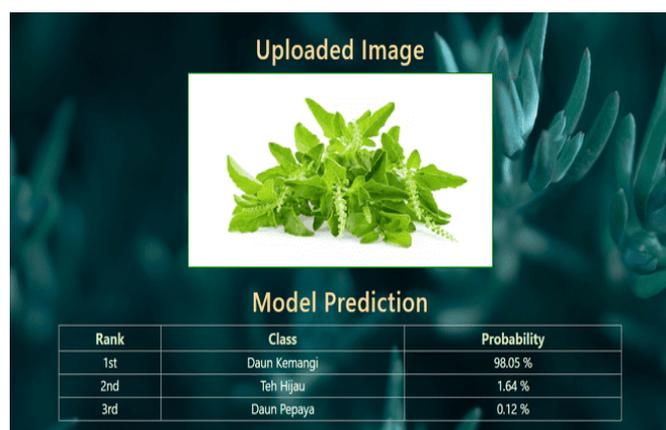


Gambar 14. Tampilan Homepage

Pada Homepage user bisa meng upload gambarnya yang telah tersedia di perangkatnya. Untuk gambar yang digunakan harus gambar yang jelas tanpa background atau latar putih agar program bisa mendeteksi dengan lebih akurat. Untuk contoh hasil jalannya program bisa dilihat pada gambar gambar dibawah.



Gambar 15. Lidah Buaya



Gambar 16. Daun Kemangi

Program dapat mengidentifikasi jenis tanaman herbal melalui gambar yang di upload ke website, disini peneliti melakukan pengambilan gambar secara manual dengan menfoto tanaman lidah buaya secara langsung serta mengambil gambar di internet pada gambar tanaman daun kemangi. Pada gambar lidah buaya dan daun kemangi program berhasil mengidentifikasi jenis tanaman herbal dengan benar dan probabilitas yang tinggi.

#### IV. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan kinerja EfficientNetB7 dan MobileNetV2 dalam klasifikasi jenis tanaman herbal menggunakan Convolutional Neural Network (CNN), dengan fokus utama untuk mencapai pengenalan otomatis tanaman herbal dengan tingkat akurasi yang tinggi. Hasil evaluasi menunjukkan bahwa baik EfficientNetB7 maupun MobileNetV2 berhasil mencapai tingkat akurasi sekitar 98% dalam mengidentifikasi jenis tanaman herbal. Meskipun keduanya menunjukkan performa yang sangat baik dalam precision, recall, dan F1-score untuk sebagian besar jenis tanaman, EfficientNetB7 menonjol dengan performa yang lebih tinggi dalam beberapa metrik evaluasi. EfficientNetB7 menunjukkan keunggulan dalam akurasi, precision, recall, dan F1-score, dibandingkan dengan MobileNetV2. Performa yang lebih tinggi ini terutama disebabkan oleh kemampuan EfficientNetB7 untuk mengelola kompleksitas dan variasi yang ada dalam data tanaman herbal yang beragam. Temuan ini memberikan wawasan yang berharga tentang potensi implementasi arsitektur CNN, seperti EfficientNetB7, dalam pengembangan sistem pengenalan tanaman herbal secara otomatis. Hal ini mendukung pengembangan sistem berbasis web yang dapat digunakan secara luas dalam pengidentifikasi tanaman herbal, dengan keunggulan dalam akurasi dan kemampuan klasifikasi yang superior.

#### DAFTAR PUSTAKA

- [1] Grenvilco et al, "Vol. 16 No. 3 / Juli - September 2023," *Pemanfaat. Tanam. Herb. Sebagai Obat Tradis. Untuk Kesehat. Masy. Di Desa Guaan Kec. Mooat Kabupaten Bolaang Mongondow Timur*, vol. 16, no. 3, pp. 1–20, 2023.
- [2] M. I. Rahayu, R. Jaenal, and M. H. Risyandi, "Identifikasi Tanaman Obat Herbal Berbasis Citra," *J. Teknol. Inf. dan Komunikas*, vol. 12, no. 2, pp. 57–63, 2023, [Online]. Available: <https://www.researchgate.net/publication/377158403>
- [3] B. Setiyono et al., "Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN)," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 2, pp. 385–392, 2023, doi: 10.25126/jtiik.20231026809.
- [4] K. U. S. D. Reddy, A. Shaik, A. Balasundaram, M. S. Nithin, L. S. R. Kakarla, and S. Noor Mahammad, "Classification of Indian Medicinal Leaves using Transfer Learning based Convolutional Neural Networks," in *2022 3rd International Conference on Smart Electronics and Communication (ICOSEC)*, 2022, pp. 1050–1058. doi: 10.1109/ICOSEC54921.2022.9952074.
- [5] S. A. E. ALBAKIA and R. A. Saputra, "Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model VGG16," *J. Inform. Polinema*, vol. 9, no. 4, pp. 451–460, 2023, doi: 10.33795/jip.v9i4.1420.
- [6] A. M. Atha and E. Zuliarsa, "Deteksi Tanaman Herbal Khusus Untuk Penyakit Kulit Dan Penyakit Rambut Menggunakan Convolutional Neural Network (CNN) Dan Tensorflow," *J. JUPITER*, vol. 4 (2), pp. 1–10, 2022.
- [7] R. Inggi, M. Mardin, M. Siregar, and A. Asmira, "Sistem Informasi Pemanfaatan Tanaman Herbal Untuk Pengobatan Berbasis Android," *Simkom*, vol. 8, no. 1, pp. 39–54, 2023, doi: 10.51717/simkom.v8i1.101.
- [8] L. Listyalina, I. Buyung, A. Q. Munir, I. Mustiadi, and D. A. Dharmawan, "Conv-Tire: Tire Feasibility Assessment using Convolutional Neural Networks Conv-Tire: Asesmen Kelayakan Ban berbasis Convolutional Neural Network," *J. Inform. dan Teknol. Inf.*, vol. 19, no. 3, pp. 323–336, 2022, doi: 10.31515/telematika.v19i3.7697.
- [9] A. M. ATHA, "Dataset Tanaman Herbal," [www.kaggle.com](https://www.kaggle.com/datasets/aneftamutiaraatha/dataset-tanaman-herbal/data). Accessed: May 02, 2024. [Online]. Available: <https://www.kaggle.com/datasets/aneftamutiaraatha/dataset-tanaman-herbal/data>
- [10] P. Purwanto and S. Sumardi, "Perancangan Klasifikasi Tanaman Herbal Menggunakan Transfer Learning Pada Algoritma Convolutional Neural Network (CNN)," *J. Ilm. Infokam*, vol. 18, no. 2, pp. 105–118, 2022, doi: 10.53845/infokam.v18i2.328.
- [11] A. Primajaya and B. N. Sari, "Random Forest Algorithm for Prediction of Precipitation," *Indones. J. Artif. Intell. Data Min.*, vol. 1, no. 1, p. 27, 2018, doi: 10.24014/ijaidm.v1i1.4903.
- [12] M. F. Atthaariq, "RANCANGAN MODEL BINARY CLASSIFICATION GAMBAR PRODUK ZIPPER DENGAN MOBILENETV2," vol. 2, no. 10, pp. 1–6, 2024.
- [13] N. Yehia and A. Samy, "An Enhancement Technique to Diagnose Colon and Lung Cancer by using Double CLAHE and Deep Learning An Enhancement Technique to Diagnose Colon and Lung Cancer by using Double CLAHE and Deep Learning," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, p. 2022, Aug. 2022.
- [14] F. A. A. Harahap, A. N. Nafisa, E. N. D. B. Purba, and N. A. Putri, "Implementasi Algoritma Convolutional Neural Network Arsitektur Model Mobilenetv2 Dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary Dan Meningioma," *J. Teknol. Informasi, Komputer, dan Apl. (JTika)*, vol. 5, no. 1, pp. 53–61, 2023, doi: 10.29303/jtika.v5i1.234.
- [15] M. Sandler, A. Howard, M. Zhu, and A. Zhmoginov, "Sandler\_MobileNetV2\_Inverted\_Residuals\_CVPR\_2018\_paper.pdf," *arXiv*, pp. 4510–4520, 2018.