

Implementasi Algoritma CNN dengan Arsitektur MobileNet untuk Klasifikasi Citra Daun Herbal

Fida Maisa Hana^{1*}, Agung Prihandono¹, Agung Bakti¹, Nuril Lutvi Azizah², Imam Prayogo Pujiono³

¹Program Studi Ilmu Komputer, Universitas Muhammadiyah Kudus, Kudus, Indonesia

²Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Sidoarjo, Indonesia

³Program Studi Informatika, UIN KH Abdurrahman Wahid Pekalongan, Pekalongan, Indonesia

Email: ¹fidamaisa@umkudus.ac.id, ²agungdono@umkudus.ac.id, ³42022110001@std.umku.ac.id, ⁴nurillutviiazizah@umsida.ac.id,

⁵imam.prayogo.p@uingusdur.ac.id

Email Penulis Korespondensi: fidamaisa@umkudus.ac.id

Submitted 29-12-2025; Accepted 27-01-2026; Published 28-02-2026

Abstrak

Keanekaragaman Indonesia sangat kaya, salah satunya adalah Indonesia memiliki tanaman herbal yang dipercaya masyarakat sebagai obat alami dalam menyembuhkan penyakit. Daun herbal menunjukkan variasi yang berbeda dalam berbagai ukuran dan bentuk untuk setiap jenis, yang menunjukkan bahwa karakteristik, bentuk, tekstur, dan ukuran khusus setiap daun. Peneliti menggunakan salah satu metode *Deep Learning* yaitu *Convolutional Neural Network* (CNN) untuk klasifikasi daun herbal. Bidang klasifikasi citra telah menemukan CNN cukup efektif untuk klasifikasi citra. CNN adalah jenis jaringan saraf dengan lapisan konvolusi yang memiliki kemampuan untuk secara otomatis mengekstraksi fitur penting dari citra. MobileNet merupakan salah satu struktur CNN yang dibuat oleh Google yang memiliki keunggulan dalam efisiensi penggunaan sumber daya komputasi. Secara khusus, dalam model jaringan MobileNet, modul perhatian ditambahkan untuk meningkatkan kemampuan model untuk mengekstrak fitur citra yang lebih rinci, dan teknologi dropout ditambahkan untuk mencegah overfitting. Metode penelitian ini mencakup tahapan prapemrosesan citra, pelatihan model berbasis convolutional neural network, dan evaluasi kinerja menggunakan metrik akurasi, presisi, *recall*, dan *F1 Score*. Pelatihan dilakukan selama 20 *epoch*, dan pengujian dilakukan menggunakan data yang dipisahkan dari data latihan. Hasil evaluasi menunjukkan bahwa model MobileNet memiliki kemampuan untuk mengekstraksi fitur visual dan menghasilkan klasifikasi citra daun herbal dengan tingkat akurasi sebesar 97,50% dan skor presisi, *recall*, dan *F1 score* masing-masing sebesar 98%. Model yang diusulkan dapat digunakan dalam aplikasi identifikasi daun herbal berbasis perangkat bergerak karena memiliki performa yang tinggi dan arsitektur yang ringan. Kurva akurasi yang stabil pada *epoch* akhir menunjukkan bahwa model tidak mengalami overfitting yang signifikan dan mampu melakukan generalisasi dengan baik terhadap data pengujian.

Kata Kunci: Klasifikasi; Daun Herbal; Deep Learning; CNN; MobileNet

Abstract

Indonesia's diversity is very rich, one of which is that Indonesia has herbal plants which people believe are natural medicines for curing diseases. Herbal leaves show different variations in size and shape for each type, indicating that each leaf has special characteristics, shape, texture and size. Researchers used one of the Deep Learning methods, namely Convolutional Neural Network (CNN) for classifying herbal leaves. The field of image classification has found CNNs to be quite effective for image classification. CNN is a type of neural network with convolutional layers that has the ability to automatically extract important features from images. MobileNet is a CNN structure created by Google. MobileNet has advantages in efficient use of computing resources. Specifically, in the MobileNet network model, an attention module was added to improve the model's ability to extract more detailed image features, and dropout technology was added to prevent overfitting. This research method includes image preprocessing, training a convolutional neural network-based model, and evaluating its performance using accuracy, precision, *recall*, and F1 score metrics. Training was conducted for 20 *epochs*, and testing was conducted using data separated from the training data. The evaluation results show that the MobileNet model has the ability to extract visual features and produce herbal leaf image classification with an accuracy rate of 97.50% and precision, *recall*, and F1 scores of 98% each. The proposed model can be used in mobile-based herbal leaf identification applications due to its high performance and lightweight architecture. The stable accuracy curve at the final *epoch* indicates that the model does not experience significant overfitting and is able to generalize well to the test data.

Keywords: Classification; Herbal Leaves; Deep Learning; CNN; MobileNet

1. PENDAHULUAN

Keanekaragaman Indonesia sangat kaya, salah satunya adalah Indonesia memiliki tanaman herbal yang dipercaya masyarakat sebagai obat alami dalam menyembuhkan penyakit [1]. Kurang lebih ada 7.000 tanaman obat di Indonesia memiliki khasiat sebagai obat [2]. Tanaman obat digunakan di Indonesia sebagai bahan untuk jamu gendong, obat herbal, makanan yang meningkatkan daya tahan tubuh, kosmetik dan spa, dan industri makanan dan minuman [3].

Daun herbal menunjukkan variasi yang berbeda dalam berbagai ukuran dan bentuk untuk setiap jenis, yang menunjukkan bahwa karakteristik, bentuk, tekstur, dan ukuran khusus setiap daun [4]. Banyak daun herbal mirip satu sama lain, yang membuat masyarakat sulit membedakannya [5]. Banyak tanaman di Indonesia mungkin terbuang oleh masyarakat karena dianggap liar dan tidak dapat digunakan sepenuhnya karena faktor-faktor tersebut. Dengan pengetahuan masyarakat yang menurun, budaya penggunaan tanaman obat tradisional dapat terkikis [6]. Penelitian terkait klasifikasi daun herbal sangat bermanfaat untuk membantu masyarakat membedakan setiap jenis daun herbal. Salah satu cara untuk mengklasifikasikan daun herbal adalah dengan mengambil citra dari daun tersebut dan menggunakan teknik pengolahan citra digital untuk melakukan analisis strukturnya. Proses ini melibatkan identifikasi citra untuk mengevaluasi karakteristik struktural daun [4].

Peneliti menggunakan salah satu metode *Deep Learning*, yaitu *Convolutional Neural Network (CNN)* untuk melakukan klasifikasi daun herbal. Dalam bidang klasifikasi citra, CNN telah terbukti mampu mengekstrak fitur visual secara otomatis dan memiliki tingkat klasifikasi yang tinggi pada berbagai objek [7][8][9][10][11][12][13][14]. CNN telah digunakan dalam beberapa penelitian sebelumnya untuk mengidentifikasi objek dalam bidang kesehatan dan pertanian. Salah satunya adalah penelitian yang dilakukan oleh Laura Falaschetti dengan judul "A CNN-based image detector for plant leaf diseases". Hasil penelitian menunjukkan bahwa detektor citra berbasis CNN ini dapat diimplementasikan secara efektif pada sistem sumber daya terbatas yang dipilih, mencapai akurasi sekitar 98,10% dan 95,24% [15]. Selain itu, penelitian oleh Snehil Baba dengan judul "Retinal Disease Classification Using Custom CNN Model From OCT Images" Model yang diusulkan memiliki kinerja yang baik dan mendapatkan akurasi validasi masing-masing sebesar 97% dan 93% [7]. Meskipun penelitian tersebut menunjukkan kinerja CNN yang baik, sebagian besar masih menggunakan arsitektur CNN konvensional atau custom dengan jumlah parameter yang relatif besar. Akibatnya, mungkin kurang cocok untuk digunakan pada perangkat yang memiliki sumber daya komputasi yang terbatas.

CNN adalah jenis jaringan saraf dengan lapisan konvolusi yang memiliki kemampuan untuk secara otomatis mengekstraksi fitur penting dari citra. MobileNet merupakan salah satu struktur CNN yang dibuat oleh Google. MobileNet memiliki keunggulan dalam efisiensi penggunaan sumber daya komputasi [16]. Secara khusus, dalam model jaringan MobileNet, modul perhatian ditambahkan untuk meningkatkan kemampuan model untuk mengekstrak fitur citra yang lebih rinci, dan teknologi dropout ditambahkan untuk mencegah overfitting [17]. MobileNets memperkenalkan konvolusi yang dapat dipisahkan secara mendalam untuk meningkatkan kecepatan dan efisiensi, secara signifikan mengurangi parameter dan perhitungan sambil tetap unggul dalam tugas klasifikasi citra [18]. Pada penelitian [19], model MobileNet menunjukkan kinerja yang unggul dengan tingkat akurasi sebesar 0,980 pada klasifikasi penyakit serta 0,975 dalam membedakan antara daun sehat dan daun berpenyakit. Penelitian [20] yang menggunakan dataset publik untuk menerapkan arsitektur MobileNet dan MobileNetV2 pada citra daun kacang, mereka menemukan akurasi lebih dari 97% pada data latih dan 92% pada data uji. Hasil tersebut menunjukkan bahwa MobileNet mampu memberikan akurasi yang baik sekaligus efisiensi waktu pelatihan, sehingga sesuai untuk diterapkan pada sistem deteksi penyakit daun tanaman. Penelitian lain [21] pada klasifikasi penyakit daun jagung juga menggunakan arsitektur MobileNet menunjukkan kinerja yang baik, dengan tingkat akurasi sebesar 97,83% pada data latih, 92,25% pada data validasi, dan 90,75% pada data uji, hasil penelitian ini menegaskan efektivitas MobileNet dalam klasifikasi penyakit daun tanaman secara otomatis.


Beberapa penelitian menunjukkan kemampuan MobileNet untuk memberikan kinerja klasifikasi yang tinggi dengan efisiensi waktu pelatihan yang tinggi. Namun demikian, penelitian yang berkaitan dengan penerapan MobileNet untuk klasifikasi daun herbal masih sangat sedikit, terutama yang memeriksa kinerja model dari segi akurasi, presisi, *recall*, dan *F1 Score*, serta kestabilan model terhadap overfitting. Penelitian sebelumnya lebih berfokus pada klasifikasi penyakit daun atau objek non-herbal.

Penelitian ini mengusulkan penggunaan arsitektur CNN berbasis MobileNet untuk klasifikasi citra daun herbal berdasarkan celah penelitian. Kontribusi utama penelitian ini adalah (1) penerapan MobileNet sebagai model klasifikasi daun herbal yang ringan dan efisien, (2) evaluasi performa model dengan metrik evaluasi yang lengkap, dan (3) analisis kestabilan model untuk mencegah overfitting. Oleh karena itu, penelitian ini diharapkan dapat membantu mengembangkan sistem yang tepat untuk mengidentifikasi tanaman obat yang dapat digunakan pada perangkat bergerak.

2. METODOLOGI PENELITIAN

Metode *Deep Learning* berbasis CNN dengan arsitektur MobileNet digunakan dalam penelitian ini untuk mengklasifikasikan citra daun herbal. Metodologi penelitian disusun secara sistematis untuk memastikan bahwa proses pelatihan dan evaluasi model berjalan dengan benar. Citra 1 menunjukkan alur penelitian ini, menunjukkan langkah-langkah yang dimulai dengan pengambilan dataset dan berakhir dengan evaluasi kinerja model.

Secara umum, metodologi penelitian ini terdiri dari beberapa tahapan utama yang saling berhubungan. Penelitian dimulai dengan kumpulan citra daun herbal. Kemudian, kualitas citra ditingkatkan melalui proses prapengolahan sebelum digunakan untuk pelatihan model. Setelah itu, data dibagi menjadi data uji dan data latih untuk digunakan dalam proses pembelajaran dan evaluasi model. Ketika arsitektur MobileNet digunakan untuk melakukan klasifikasi, kinerja model diuji dengan metrik evaluasi yang sesuai. Ini dilakukan untuk mengetahui seberapa akurat dan andal model dalam mengklasifikasikan citra daun herbal.



Gambar 1. Alur Penelitian

Mengacu pada gambar 1. alur penelitian, proses penelitian dimulai dari pengumpulan dataset, prapengolahan data, pembagian data, tahap klasifikasi dan berakhir dengan evaluasi.

2.1 Pengambilan Dataset

Penelitian ini menggunakan data citra daun herbal yang berasal dari Kaggle. data citra daun herbal berhasil dikumpulkan berjumlah 10 jenis daun herbal, yaitu citra belimbing wuluh, jambu biji, jeruk nipis, kemangi, lidah buaya, nangka, pandan, pepaya, seledri, dan sirih. Masing-masing jenis daun herbal memiliki 200 sampel citra, jadi total data citra adalah 2000 sampel.

2.2 Prapengolahan Data

Sebelum digunakan dalam proses pelatihan model, tahap prapengolahan data dilakukan untuk meningkatkan kualitas citra. Pada titik ini, citra daun herbal dikecilkan untuk memenuhi kebutuhan input arsitektur MobileNet. Selain itu, nilai piksel citra dinormalisasi dengan membagi setiap nilai pikselnya dengan konstanta 255, yang menciptakan rentang nilai mulai dari 0 hingga 1. Proses ini digunakan untuk mempercepat konvergensi dan menjaga nilai numerik stabil selama pelatihan model. Teknik augmentasi data juga digunakan untuk meningkatkan variasi data latih dan mengurangi kemungkinan overfitting. Teknik ini memungkinkan model untuk memperoleh representasi fitur yang lebih beragam, yang berarti kemampuan model untuk mengekstraksi fitur visual dari citra daun herbal menjadi lebih baik. Setiap tahapan pra-pengolahan dimaksudkan untuk meningkatkan kinerja model selama proses klasifikasi citra.

2.3 Pembagian Data


Dataset yang digunakan dalam penelitian ini terdiri dari 2.000 citra daun herbal yang terbagi ke dalam sepuluh kelas. Data tersebut dibagi menjadi dua bagian, 1.600 citra sebagai data latih dan 400 citra sebagai data uji, dengan proporsi masing-masing 80% dan 20%. Untuk memastikan distribusi data yang seimbang, pembagian data dilakukan secara proporsional untuk setiap kelas citra daun herbal.

2.4 Klasifikasi dengan MobileNet

Pada tahap ini, klasifikasi citra daun herbal dilakukan menggunakan metode *Deep Learning* berbasis CNN dengan arsitektur MobileNet. MobileNet dipilih karena kemampuan untuk mengekstraksi fitur citra dengan jumlah parameter yang relatif kecil, yang membuatnya cocok untuk klasifikasi citra daun herbal. Subbagian ini memberikan penjelasan tentang konsep dasar CNN yang digunakan sebagai dasar metode yang digunakan. Ini juga membahas bagaimana arsitektur MobileNet digunakan untuk proses klasifikasi citra dalam penelitian ini.

2.4.1. Convolution Neural Network (CNN)

Salah satu algoritma yang termasuk dalam deep learning adalah CNN. CNN termasuk ke dalam jenis deep neural network karena kedalaman jaringannya yang tinggi dan sering digunakan pada data citra. CNN memiliki kemampuan untuk melakukan perhitungan matematis pada input yang terdiri dari berbagai lapisan tersembunyi. Lapisan tersembunyi mengatur input citra, dan bagian output mengirimkan hasil pemrosesan. Lapisan konvolusi CNN berguna untuk mengekstraksi fitur dan bagian klasifikasi untuk mengklasifikasi fitur ke dalam kelas pelatihan yang telah ditentukan sebelumnya [22]. Pelatihan membutuhkan lebih banyak waktu dan membutuhkan perangkat komputer yang baik. Namun, prediksi CNN cukup akurat dan cepat. Gambar 2 berikut menunjukkan jaringan arsitektur convolutional neural network.




Gambar 2. Jaringan Arsitektur CNN

Alur kerja arsitektur CNN terdiri dari dua tahap utama: *feature learning* dan klasifikasi, seperti yang dicitrakan pada Citra 1. Pada tahap pembelajaran fitur, citra yang dimasukkan diproses melalui lapisan konvolusi bersama dengan fungsi aktivasi dan pooling untuk secara bertahap mengekstraksi fitur-fitur penting. Pada tahap klasifikasi, fitur hasil ekstraksi diubah ke dalam bentuk vektor melalui proses flatten, kemudian diproses melalui lapisan yang penuh terhubung dan fungsi aktivasi softmax untuk menghasilkan prediksi kelas citra.

2.4.2. Arsitektur MobileNet

MobileNet adalah arsitektur Convolutional Neural Network (CNN) yang dimaksudkan untuk digunakan dalam aplikasi komputasi dan perangkat mobile yang memiliki sumber daya terbatas. MobileNet, yang dirilis oleh tim Google pada tahun 2017, berfokus pada kecepatan dan efisiensi sambil tetap memiliki kinerja yang baik dalam pengenalan citra [17]. MobileNet menawarkan model yang efektif untuk aplikasi mobile dan visi tertanam karena arsitekturnya yang sederhana. MobileNet menggunakan konvolusi yang dapat dipisahkan secara mendalam untuk membangun deep convolutional neural networks yang ringan[23]. Struktur MobileNet bergantung pada filter yang dapat dipisahkan. Gambar 3 dibawah ini menunjukkan struktur arsitektur MobileNet [24].



Gambar 3. Struktur arsitektur MobileNet

Dari gambar arsitektur diatas, bagian a adalah lapisan Depthwise Convolution, bagian b adalah lapisan Pointwise Convolution, dan bagian c adalah blok dasar dari arsitektur MobileNet yang dikenal sebagai depthwise separable convolution block, yang memiliki penjelasan untuk setiap komponennya di sini:

a. 3x3 Depthwise Convolution:

Dengan menggunakan filter konvolusi 3x3 pada setiap channel input, jumlah parameter dan komputasi dikurangi karena konvolusi dilakukan secara terpisah pada setiap channel daripada menggabungkan semua channel. Pada depthwise convolution, setiap filter diterapkan secara terpisah pada setiap channel dari input.

Jika kita memiliki input dengan $D_F \times D_F \times M$ dan filter $D_k \times D_k \times M$, di mana:

1. D_F adalah dimensi spasial dari input (panjang atau lebar).
2. M adalah jumlah channel dari input.
3. D_k adalah dimensi kernel (biasanya 3x3).

Rumus operasi depthwise convolution adalah:

$$Output_{depthwise} = Input * Filter_{depthwise} \quad (1)$$

Setiap filter digunakan pada masing-masing channel, menghasilkan output berukuran: $D'_F \times D'_F \times M$

b. *Batch Normalization*

Setelah convolution depthwise, normalisasi batch dilakukan untuk menstabilkan dan mempercepat proses pelatihan dengan menormalisasi output dari lapisan convolusi.

c. *ReLU*

Non-linearitas ditambahkan ke model melalui penggunaan fungsi aktivasi Rectified Linear Unit (ReLU).

d. *1x1 Pointwise Convolution*:

Convulasi 1x1 menggabungkan channel output dari convolution depthwise dan memungkinkan integrasi informasi antar channel. Ini menambah jumlah parameter, tetapi masih lebih efisien daripada convolution standar. Setelah *depthwise convolution*, *pointwise convolution* digunakan untuk menggabungkan informasi dari berbagai channel. Ini dilakukan dengan convulasi 1x1 pada output dari *depthwise convolution*.

Rumus untuk *pointwise convolution* adalah:

$$Output_{pointwise} = Output_{depthwise} * Filter_{pointwise} \quad (2)$$

Jika output dari *depthwise convolution* memiliki ukuran $D'_F \times D'_F \times M$ maka filter *pointwise* memiliki dimensi $1 \times 1 \times M \times N$, dimana N adalah jumlah channel dari output yang diinginkan. Sehingga, total parameter untuk *depthwise separable convolution* adalah:

$$DK \times DK \times M + M \times N \quad (3)$$

Jumlah Operasi (FLOPs)

1. Depthwise Convolution:

$$D_k \times D_k \times D_F \times D_F \times M \quad (4)$$

2. Pointwise Convolution:

$$D'_F \times D'_F \times M \times N \quad (5)$$

Total operasi (FLOPs) untuk *depthwise separable convolution* adalah:

$$D_k \times D_k \times D_F \times D_F \times M + D'_F \times D'_F \times M \times N \quad (6)$$

e. *Batch Normalization* (lagi):

Untuk meningkatkan stabilitas output layer ini, normalisasi batch kedua dilakukan setelah convolution pointwise.

f. *ReLU* (lagi):

Untuk memastikan bahwa non-linearitas tetap ada di layer ini, fungsi aktivasi ReLU diterapkan lagi setelah convolution pointwise.

Komponen dari arsitektur MobileNet dan bertanggung jawab atas kinerja dan efisiensi komputasi yang luar biasa dari model ini. MobileNet sangat cocok untuk aplikasi pada perangkat dengan keterbatasan sumber daya karena *depthwise separable convolutions* secara signifikan mengurangi jumlah parameter dan operasi komputasi dibandingkan dengan convulasi standar.

2.5 Evaluasi Kinerja Model

Data uji yang telah dipisahkan sebelumnya digunakan untuk menilai kinerja model. Pengujian dilakukan dengan menggunakan *confusion matrix* untuk menghitung metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1 Score*. Metrik-metrik ini digunakan untuk menilai kemampuan model untuk mengklasifikasikan citra daun herbal secara akurat dan konsisten. Untuk mengetahui seberapa efektif model MobileNet yang diusulkan, hasil evaluasi selanjutnya dianalisis pada bagian hasil dan pembahasan.

3. HASIL DAN PEMBAHASAN

Berdasarkan tahapan metodologi penelitian yang telah dijelaskan sebelumnya, bagian ini menyajikan hasil eksperimen dan diskusi tentang kinerja model klasifikasi citra daun herbal yang dikembangkan menggunakan arsitektur MobileNet. Evaluasi dilakukan untuk mengetahui seberapa efektif model dalam mengklasifikasikan citra daun herbal. Pembahasan difokuskan pada proses implementasi model, hasil pelatihan, dan analisis kinerja model menggunakan metrik evaluasi yang digunakan.

3.1 Pengambilan Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 2.000 citra daun herbal yang dibagi ke dalam sepuluh kelas: belimbing wuluh, jambu biji, jeruk nipis, kemangi, lidah buaya, nangka, pandan, pepaya, seledri, dan sirih. Data ini

diambil dari platform Kaggle. Setiap kelas memiliki dua ratus citra, sehingga distribusi data antar kelas seimbang. Kondisi ini membantu proses pelatihan model karena menghindari bias terhadap kelas tertentu dan memungkinkan penilaian kinerja model yang lebih objektif. Sampel citra daun herbal untuk setiap kelas ditunjukkan pada Tabel 1.

Tabel 1. Sampel Citra Daun Herbal

	
Jambu Biji	Belimbing Wuluh
	
Jeruk Nipis	Kemangi
	
Pepaya	Nangka
	
Lidah Buaya	Pandan
	
Seledri	Sirih

Setiap kelas daun herbal yang digunakan dalam penelitian ini dicitrakan dalam Tabel 1. Setiap citra menunjukkan karakteristik visual daun herbal, seperti bentuk, tekstur, dan pola tulang daun. Karakteristik-karakteristik ini sangat penting untuk proses pembelajaran model. Kehadiran sampel citra pada setiap kelas dimaksudkan untuk menunjukkan variasi data yang digunakan dan membantu proses klasifikasi citra daun herbal secara lebih akurat.

3.2 Prapengolahan Data

Pada tahap prapengolahan, citra daun herbal secara keseluruhan disesuaikan ukurannya agar sesuai dengan dimensi input arsitektur MobileNet. Kemudian, proses normalisasi dilakukan dengan membagi setiap nilai piksel citra dengan konstanta 255, sehingga nilai piksel berada dalam rentang 0 hingga 1. Proses normalisasi ini dilakukan dengan tujuan memastikan bahwa nilai numerik tetap stabil selama proses pelatihan dan untuk mempercepat proses konvergensi model.

Untuk meningkatkan keragaman sampel citra, metode augmentasi data digunakan pada data latih selain normalisasi. Untuk augmentasi, hanya beberapa perubahan dilakukan pada citra, seperti perubahan orientasi dan skala, tetapi karakteristik utama dari daun tidak diubah. Metode ini menurunkan risiko overfitting, yang ditunjukkan oleh kestabilan kurva akurasi pada tahap pelatihan, serta membantu model MobileNet dalam mempelajari fitur yang lebih kuat. Secara keseluruhan, proses prapengolahan data sangat penting untuk meningkatkan kualitas data masukan, yang memungkinkan model untuk mengekstraksi fitur visual daun herbal dengan lebih baik dan menghasilkan kinerja klasifikasi yang lebih konsisten pada data uji.

3.3 Pembagian Data

- Dataset penelitian terdiri dari 2.000 citra daun herbal, yang dibagi ke dalam sepuluh kelas, masing-masing dengan jumlah citra yang seimbang.

- b. Data dibagi menjadi 1.600 citra sebagai data latih (80 persen) dan 400 citra sebagai data uji (20 persen). Dengan demikian, model memiliki cukup data untuk mempelajari pola fitur dan melakukan evaluasi pada data yang tidak termasuk dalam proses pelatihan.
- c. Data dibagi secara proporsional untuk setiap kelas, sehingga tidak ada ketimpangan jumlah data yang dapat memengaruhi hasil evaluasi kinerja model.
- d. Distribusi data yang seimbang ini meningkatkan stabilitas proses pelatihan dan membantu model MobileNet generalisasi data uji dengan baik.

3.4 Klasifikasi dengan MobileNet

Pada tahap klasifikasi, penelitian ini menggunakan arsitektur MobileNet untuk mengklasifikasikan citra daun herbal dengan menggunakan API Fungsional Keras dan TensorFlow sebagai backend. MobileNet digunakan sebagai model utama dalam proses ekstraksi fitur karena arsitekturnya yang ringan dan efektif dan cocok untuk klasifikasi citra dengan sumber daya komputasi yang terbatas.

Untuk menyesuaikan model dengan persyaratan klasifikasi sepuluh kelas citra daun herbal, beberapa lapisan ditambahkan pada bagian akhir arsitektur. Lapisan konvolusi (Conv2D) dengan 16 filter, ukuran kernel 3×3, padding "sama", dan fungsi aktivasi ReLU digunakan untuk mengekstraksi fitur lokal citra. Lapisan pengumpulan maksimum juga digunakan untuk mengurangi dimensi fitur dan mempertahankan data yang paling dominan.

Ditambahkan lapisan dropout dengan nilai rate dropout 0,5 untuk meningkatkan kemampuan generalisasi model dan mencegah overfitting. Setelah melalui lapisan flatten, output fitur diubah menjadi vektor satu dimensi. Selanjutnya, sebagai tahap akhir dari proses klasifikasi, lapisan dense digunakan. Pada setiap kelas citra daun herbal, lapisan dense menghasilkan probabilitas prediksi dengan menggunakan fungsi aktivasi softmax.

Kombinasi arsitektur MobileNet dengan lapisan tambahan tersebut memungkinkan model untuk menghasilkan representasi fitur yang informatif dan stabil serta memberikan kinerja klasifikasi yang baik pada data uji. Hasil evaluasi kinerja model dibahas selanjutnya menggunakan metrik akurasi, presisi, *recall*, dan *F1 Score*.

3.5 Evaluasi Kinerja Model

Pengujian dilakukan dengan 400 data uji yang tidak termasuk pada tahap pelatihan untuk mengevaluasi kemampuan model MobileNet dalam mengklasifikasikan citra daun herbal. Untuk mengevaluasi kinerja model, *confusion matrix* digunakan untuk menghitung metrik akurasi, presisi, *recall*, dan *F1 Score*. Selain itu, perubahan nilai akurasi dan hilang selama proses pelatihan diamati untuk mengevaluasi stabilitas pembelajaran model. Hasil pengujian menunjukkan bahwa pada *epoch* ke-20, model MobileNet mencapai akurasi sebesar 97,50%. Tabel 2 menunjukkan perubahan nilai akurasi dan *loss* pada setiap *epoch* selama proses pelatihan.


Tabel 2. Perubahan *Accuracy* dan *Loss*

<i>Epoch</i>	<i>Accuracy</i>	<i>Loss</i>
1	0.2256	33.372
2	0.5091	13.332
3	0.7272	0.7981
4	0.8182	0.5601
5	0.8594	0.4097
6	0.8988	0.3055
7	0.9340	0.2161
8	0.9476	0.1697
9	0.9489	0.1545
10	0.9573	0.1396
11	0.9613	0.1219
12	0.9687	0.0997
13	0.9702	0.0858
14	0.9811	0.0771
15	0.9804	0.0653
16	0.9761	0.0670
17	0.9893	0.0436
18	0.9733	0.0696
19	0.9896	0.0391
20	0.9874	0.0444

Tabel 2 menunjukkan peningkatan signifikan dalam nilai akurasi model MobileNet pada tahap awal pelatihan, diikuti oleh penurunan yang signifikan dalam nilai *loss*. Ini menunjukkan bahwa model mampu mempelajari fitur-fitur penting dari citra daun herbal sejak awal pelatihan. Akurasi meningkat dengan waktu, tetapi *loss* terus menurun hingga mencapai nilai yang relatif rendah.

Nilai akurasi cenderung konvergen dengan fluktuasi kecil pada periode akhir, sedangkan nilai *loss* berada pada kisaran yang rendah. Kondisi ini menunjukkan bahwa proses pelatihan telah mencapai keadaan stabil dan bahwa tidak

ada overfitting yang signifikan pada model. Dengan demikian, tingginya nilai akurasi yang diperoleh pada akhir pelatihan menunjukkan bahwa model MobileNet yang diusulkan memiliki kemampuan generalisasi yang baik terhadap data uji. Grafik perubahan nilai akurasi pada setiap *epoch* ditampilkan untuk memberikan citraan visual tentang bagaimana kinerja model selama proses pelatihan. Kami menggunakan grafik ini untuk melihat bagaimana kemampuan MobileNet dalam mempelajari pola dan fitur pada citra daun herbal telah berubah seiring waktu.



Gambar 4. Grafik Akurasi

Nilai akurasi model meningkat secara signifikan pada periode awal dan kemudian menjadi lebih stabil hingga mencapai kondisi konvergen pada periode akhir, seperti yang ditunjukkan oleh grafik akurasi yang ditampilkan pada Citra 4. Pola ini menunjukkan bahwa proses pelatihan berjalan dengan baik, dan model mampu mempelajari fitur citra daun herbal tanpa mengalami overfitting yang signifikan.

Untuk menilai kemampuan model MobileNet untuk melakukan klasifikasi citra daun herbal yang menyeluruh, hasil evaluasi kinerja model pada data uji disajikan dalam bentuk metrik akurasi, presisi, *recall*, dan *F1 Score*. Nilai masing-masing metrik ditampilkan dalam Tabel 3.

Tabel 3. Hasil *Confusion Matrix*

Akurasi	97,50%.
Presisi	98%.
Recall	98%.
F1-Score	98%.

Berdasarkan hasil evaluasi kinerja yang ditunjukkan pada Tabel 3, model MobileNet yang diusulkan mencapai akurasi sebesar 97,50%. Selain itu, nilai presisi, *recall*, dan *F1-score*, yang masing-masing mencapai 98%, menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik dan seimbang. Nilai presisi yang tinggi berarti sebagian besar prediksi yang dibuat oleh model adalah benar, sedangkan nilai *recall* yang tinggi berarti model dapat secara konsisten mengenali semua kelas citra daun herbal. Keseimbangan antara presisi dan *recall*, seperti yang ditunjukkan oleh nilai *F1-score*, menunjukkan bahwa model bekerja dengan andal selama proses klasifikasi citra.

4. KESIMPULAN

Hasil penelitian menunjukkan bahwa metode CNN dengan arsitektur MobileNet berhasil menyelesaikan masalah klasifikasi citra daun herbal. Model yang dibangun dapat mengoptimalkan fitur visual daun herbal, yang menghasilkan kinerja klasifikasi yang tinggi. Hasil evaluasi menunjukkan bahwa model MobileNet memiliki tingkat akurasi sebesar 97,50%, nilai presisi dan *recall* masing-masing sebesar 98%, dan nilai F1 sebesar 98%. Hasil ini menunjukkan bahwa model memiliki kinerja yang seimbang dalam menghasilkan prediksi yang akurat dan konsisten pada seluruh kelas daun herbal. Selain itu, kestabilan peningkatan akurasi dan penurunan nilai *loss* selama proses pelatihan menunjukkan bahwa model memiliki kemampuan generalisasi yang baik. Oleh karena itu, penelitian ini menunjukkan bahwa arsitektur MobileNet adalah solusi klasifikasi citra daun herbal yang efektif dan dapat diandalkan, yang dapat digunakan pada sistem identifikasi tanaman herbal berbasis teknologi digital.

REFERENCES

- [1] F. Hidayanto and D. S. Ardi, "Tanaman herbal sebagai tanaman hias dan tanaman obat," *J. Inov. dan Kewirausahaan*, vol. 4, no. 1, pp. 1–4, 2015.
- [2] S. Siahaan and N. K. Aryastami, "Studi Kebijakan Pengembangan Tanaman Obat di Indonesia," *Media Penelit. dan Pengemb.*

- Kesehat.*, vol. 28, no. 3, pp. 157–166, 2018, doi: 10.22435/mpk.v28i3.119.
- [3] E. R. Pribadi, “Pasokan Dan Permintaan Tanaman Obat Indonesia Serta Arah Penelitian Dan Pengembangannya (Supply And Demand Of Indonesian Medicinal Plants And The Research And Development Direction),” *Perspektif*, vol. 8, no. 1, pp. 52–64, 2017, [Online]. Available: <http://ejurnal.litbang.pertanian.go.id>
 - [4] S. P. Backar, P. Purnawansyah, H. Darwis, and W. Astuti, “Hybrid Fourier Descriptor Naïve Bayes dan CNN pada Klasifikasi Daun Herbal,” *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 126–133, 2023, doi: 10.30591/jpit.v8i2.5186.
 - [5] L. P. R. Noviana and I. N. B. S. Nugraha, “Perbandingan Klasifikasi Citra Daun Herbal Menggunakan Metode Logistic Regression dan Decision Tree Classifier Berdasarkan Fitur (Warna, GLCM, Bentuk),” *JITU J. Inform. Technol. Commun.*, vol. 7, no. 2, pp. 126–133, 2023, doi: 10.36596/jitu.v7i2.1241.
 - [6] Adela Regita Azzahra, “Klasifikasi Daun Herbal Menggunakan Metode CNN dan Naïve Bayes dengan Fitur GLCM,” *Indones. J. Comput. Sci.*, vol. 12, no. 4, 2023, doi: 10.33022/ijcs.v12i4.3362.
 - [7] S. Baba, P. Kumari, and P. Saxena, “Retinal Disease Classification Using Custom CNN Model from OCT Images,” *Procedia Comput. Sci.*, vol. 235, no. 2023, pp. 3142–3152, 2024, doi: 10.1016/j.procs.2024.04.297.
 - [8] T. Bariyah, M. A. Rasyidi, and N. Ngatini, “Convolutional Neural Network untuk Metode Klasifikasi Multi-Label pada Motif Batik,” *Techno.Com*, vol. 20, no. 1, pp. 155–165, 2021, doi: 10.33633/tc.v20i1.4224.
 - [9] Y. Hao, “Convolutional Neural Networks for Image Classification,” *Proc. - 2021 2nd Int. Conf. Artif. Intell. Comput. Eng. ICAICE 2021*, vol. 8, no. 5, pp. 342–345, 2021, doi: 10.1109/ICAICES4393.2021.00073.
 - [10] A. M. P. and P. Reddy, “Ensemble of CNN models for classification of groundnut plant leaf disease detection,” *Smart Agric. Technol.*, vol. 6, no. July, p. 100362, 2023, doi: 10.1016/j.atech.2023.100362.
 - [11] N. George, L. Shine, A. N. B. Abraham, and S. Ramachandran, “A two-stage CNN model for the classification and severity analysis of retinal and choroidal diseases in OCT images,” *Int. J. Intell. Networks*, vol. 5, no. October 2023, pp. 10–18, 2024, doi: 10.1016/j.ijin.2024.01.002.
 - [12] M. H. Ahmad, F. M. Hana, T. G. Pratama, and H. Aulida, “Klasifikasi Empat Jenis Daun Herbal Menggunakan Metode Convolutional Neural Network,” *J. Ilmu Komput. dan Mat.*, vol. 4, no. 2, pp. 69–76, 2023.
 - [13] K. Umam, F. Maisa, and H. Aulida, “Klasifikasi Jenis Golongan Kendaraan Di Gerbang Tol Menggunakan Arsitektur Cnn Vgg16,” vol. 5, no. 1, pp. 10–15, 2024.
 - [14] I. P. Ahadin, A. I., Hana, F. M., Prihandono, A., & Pujiono, “Pengembangan Model Klasifikasi Produk Furnitur Sebagai Visual Search Menggunakan Algoritma Convolutional Neural Network,” vol. VIII, no. September, 2024.
 - [15] L. Falaschetti, L. Manoni, D. Di Leo, D. Pau, V. Tomaselli, and C. Turchetti, “A CNN-based image detector for plant leaf diseases classification,” *HardwareX*, vol. 12, p. e00363, 2022, doi: 10.1016/j.ohx.2022.e00363.
 - [16] S. Ramdani and A. Rahmatulloh, “Implementasi Mobilenet untuk Klasifikasi Gambar dan Deteksi Emosi Menggunakan KERAS,” vol. 12, no. 2, pp. 259–264, 2024, doi: 10.26418/justin.v12i2.73389.
 - [17] Y. Nan, J. Ju, Q. Hua, H. Zhang, and B. Wang, “A-MobileNet: An approach of facial expression recognition,” *Alexandria Eng. J.*, vol. 61, no. 6, pp. 4435–4444, 2022, doi: 10.1016/j.aej.2021.09.066.
 - [18] T. Shevchenko and T. Shevchenko, “Modern Small Networks For Image Classification. Feature Analysis,” pp. 221–229, 2024, doi: 10.32347/2412-9933.2024.60.221-229.
 - [19] H. T. Nguyen *et al.*, “An Improved MobileNet for Disease Detection on Tomato Leaves,” vol. 8, no. 3, pp. 192–209, 2023.
 - [20] E. Elfatimi, “Beans Leaf Diseases Classification Using MobileNet Models,” 2022.
 - [21] I. W. A. W. K. P. Ni Putu Dita Ariani Sukma Dewi, I Gede Hendrayana, “Optimasi Hyperparameter Convolutional Neural Network Dengan Arsitektur Mobilenet Pada Klasifikasi Penyakit Daun Jagung,” vol. 8, no. 1, pp. 92–99, 2025.
 - [22] S. Dasarathi, “Parametrization of Convolutional Neural Network for Image Classification,” no. August, 2015.
 - [23] U. Khultsum, F. Sarasati, and G. Taufik, “Penerapan Metode Mobile-Net Untuk Klasifikasi Citra Penyakit Kanker Paru-Paru,” *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 5, p. 1366, 2022, doi: 10.30865/jurikom.v9i5.4918.
 - [24] C. Bi, J. Wang, Y. Duan, B. Fu, J. R. Kang, and Y. Shi, “MobileNet Based Apple Leaf Diseases Identification,” *Mob. Networks Appl.*, vol. 27, no. 1, pp. 172–180, 2022, doi: 10.1007/s11036-020-01640-1.