

# Klasifikasi Jenis Tanaman Herbal Berdasarkan Citra Menggunakan Metode *Convolution Neural Network* (CNN)

Nurdian Kasim<sup>1\*</sup>, Muh. Bayanudin Fadilah<sup>2</sup>, Wahyu Al Hidayat<sup>3</sup>, Rizal Adi Saputra<sup>4</sup>

<sup>1, 2, 3, 4</sup>Teknik Informatika, Fakultas Teknik, Universitas Halu Oleo, Kota Kendari, Indonesia

Email: <sup>1,\*</sup> nurdiankasim1948@gmail.com, <sup>2</sup>muhammadbayanudinfadilah@gmail.com,

<sup>3</sup>wahyuahidayat11@gmail.com, <sup>4</sup>rizaladisaputra@uho.ac.id

<sup>\*</sup>) Email Penulis Utama

**Abstrak**— Indonesia, sebagai negara *megabiodiversitas*, memiliki beragam tumbuhan herbal yang dimanfaatkan secara luas oleh masyarakat untuk keperluan berbagai macam, terutama dalam bidang kesehatan. Tumbuhan herbal sering dipilih sebagai obat tradisional karena dianggap lebih aman dan memiliki *efek* samping yang minim dibandingkan dengan obat-obatan kimia. Namun, identifikasi dan klasifikasi tumbuhan herbal sering kali menjadi tantangan karena adanya kesamaan morfologi antara beberapa spesies serta keterbatasan pengetahuan botani yang tersedia. Penelitian ini bertujuan untuk mengatasi tantangan tersebut dengan mengembangkan sistem klasifikasi menggunakan *Convolutional Neural Network* (CNN). Model CNN yang dikembangkan mengadopsi arsitektur *Sequential* dengan lapisan-lapisan *konvolusi* dan *pooling*, serta memanfaatkan teknik *augmentasi* data untuk meningkatkan variasi dalam *dataset*. *Dataset* awal terdiri dari 6200 gambar dari 31 jenis tumbuhan herbal yang diambil menggunakan kamera *smartphone*. Setelah proses *augmentasi* data, yang mencakup operasi seperti rotasi, pergeseran, pemotongan, dan *flipping*, jumlah gambar yang digunakan dalam pelatihan menjadi lebih bervariasi meskipun jumlah fisiknya tetap sama yaitu 4960 gambar untuk pelatihan, 621 gambar untuk *validasi*, dan 124 gambar untuk pengujian. Hasil penelitian menunjukkan bahwa model yang dikembangkan berhasil mencapai akurasi sebesar 92.74% dalam mengklasifikasikan gambar-gambar tumbuhan herbal. Nilai *precision* dan *recall* juga menunjukkan kinerja yang kuat, dengan banyak kategori daun mencapai nilai *precision* dan *recall* sebesar 1.00, yang menandakan bahwa model ini sangat efektif dan konsisten dalam mengenali berbagai jenis daun tanaman herbal. Misalnya, kategori seperti bawang merah, bawang putih, dan bayam memiliki nilai *precision* dan *recall* yang sempurna. Namun, beberapa kategori seperti daun jambu biji dan katuk menunjukkan variasi dalam *precision* dan *recall*, yang menunjukkan perlunya lebih banyak data atau variasi dalam *dataset* untuk meningkatkan kinerja pada kategori tersebut. Pendekatan ini diharapkan dapat mendukung pemanfaatan tumbuhan herbal secara lebih *efektif* dan aman sebagai *alternatif* pengobatan yang berkelanjutan dan alami. Kontribusi signifikan dari penelitian ini adalah mengintegrasikan teknologi kecerdasan buatan, khususnya CNN, dalam mengidentifikasi dan memanfaatkan potensi tumbuhan herbal, sehingga memperkuat peran mereka dalam sistem kesehatan modern. Penelitian ini menggaris bawahi potensi AI untuk mengembangkan identifikasi dan pemanfaatan tumbuhan herbal, serta mendorong integrasi mereka ke dalam sistem kesehatan untuk meningkatkan hasil kesehatan secara keseluruhan di masa mendatang. Penelitian ini juga mendorong keberlanjutan kesehatan alami.

**Kata Kunci:** *Convolutional Neural Network* (CNN), Indonesia, Kesehatan, Sistem klasifikasi, Tanaman herbal

**Abstract**— Indonesia, as a megadiverse country, possesses a wide range of herbal plants that are extensively utilized by the community for various purposes, especially in the field of health. Herbal plants are often chosen as traditional remedies because they are considered safer and have fewer side effects compared to chemical drugs. However, identifying and classifying herbal plants can be challenging due to morphological similarities between species and limited botanical knowledge. This study aims to address these challenges by developing a classification system using *Convolutional Neural Networks* (CNN). The developed CNN model adopts a *Sequential* architecture with convolutional and pooling layers and employs data augmentation techniques to enhance variation in the dataset. The initial dataset consists of 6200 images of 31 types of herbal plants captured using a smartphone camera. After the data augmentation process, which includes operations such as rotation, shifting, cropping, and flipping, the number of images used for training becomes more diverse, although the physical count remains the same: 4960 images for training, 621 images for validation, and 124 images for testing. The research results show that the developed model achieved an accuracy of 92.74% in classifying herbal plant images. Precision and recall values also indicate strong performance, with many leaf categories achieving precision and recall values of 1.00, signifying that the model is highly effective and consistent in recognizing various types of herbal plant leaves. For instance, categories such as red onion, garlic, and spinach have perfect precision and recall values. However, some categories, such as guava leaf and katuk, show variations in precision and recall, indicating the need for more data or variation in the dataset to improve performance for these categories. This approach is expected to support the more effective and safer use of herbal plants as sustainable and natural alternatives for treatment. A significant contribution of this study is the integration of artificial intelligence technology, particularly CNNs, in identifying and utilizing the potential of herbal plants, thereby enhancing their role in modern health systems. This research highlights the potential of AI to advance the identification and utilization of herbal plants and encourages their integration into health systems to improve overall health outcomes in the future. The study also promotes the sustainability of natural health solutions.

**Keywords:** Classification system, *Convolutional Neural Network* (CNN), Healthcare, Herbal plants, Indonesia

## 1. PENDAHULUAN

Indonesia dikenal dengan julukan negara *megabiodiversity* yang tentunya memiliki banyak jenis tumbuhan herbal dengan bentuk dan struktur yang tersebar di seluruh wilayahnya[1]. Tumbuhan herbal adalah jenis tumbuhan yang sering dimanfaatkan oleh masyarakat karena memiliki banyak manfaat, seperti mencegah atau menyembuhkan berbagai penyakit[2]. Selain berperan sebagai penghasil oksigen, bahan baku makanan, dan industri, tumbuhan herbal juga memiliki peran yang signifikan dalam bidang kesehatan manusia. Tumbuhan yang digunakan secara khusus dalam pengobatan sering disebut sebagai tumbuhan herbal[3]. Fakta bahwa sekitar 80% masyarakat masih mengandalkan obat tradisional menunjukkan betapa pentingnya peran tumbuhan herbal dalam mempertahankan kesehatan manusia[4]. Tumbuhan herbal dapat digunakan untuk mengobati berbagai macam penyakit seperti penyakit jantung, gangguan pernapasan, masalah reproduksi, penyakit saluran pencernaan, masalah sendi, penyakit kulit, gangguan ekskresi, dan penyakit lainnya[5].

Pemanfaatan tumbuhan herbal sebagai obat tradisional semakin diminati karena dianggap lebih aman dan minim efek samping dibandingkan dengan obat-obatan kimia[6]. Dengan memahami manfaat dan khasiat dari berbagai jenis tumbuhan herbal, masyarakat dapat memilih pengobatan alami yang aman dan *efektif* sebagai pilihan utama mereka untuk menjaga kesehatan dan proses penyembuhan[7]. Namun, penting untuk memperhatikan cara penggunaannya, waktu konsumsi yang tepat, serta pemilihan obat yang sesuai dengan kondisi kesehatan untuk menghindari potensi efek samping yang tidak diinginkan[8]. Kekurangan pengetahuan dan informasi yang memadai sering kali membuat masyarakat kesulitan dalam membedakan tumbuhan herbal yang tepat untuk mengobati penyakit yang dihadapi, meningkatkan risiko penggunaan yang tidak *efektif* atau bahkan berbahaya bagi kesehatan[9].

Sumber bahan obat tradisional dan obat alami tersebut diperoleh dari tumbuhan herbal yang diketahui memiliki senyawa tertantuyang bermanfaat bagi kesehatan. Senyawa ini umumnya terdapat pada berbagai organ tubuh tumbuhan, seperti daun[10]. Namun, dengan munculnya berbagai obat modern terbaru dan kurangnya informasi yang memadai mengenai tumbuhan herbal, penggunaan obat tradisional tersebut mulai tergeser dan ditinggalkan secara bertahap. Dalam konteks ini, teknologi klasifikasi dapat menjadi solusi yang *efektif* untuk membantu identifikasi dan membedakan berbagai jenis tumbuhan herbal berdasarkan karakteristik dan manfaatnya[11]. Klasifikasi adalah proses untuk membangun suatu model atau fungsi yang menggambarkan konsep suatu data. Pada proses klasifikasi, sejumlah data dikumpulkan kemudian dibagi menjadi kategori-kategori tertentu yang disebut *class*. *Class* yang terbentuk dari proses ini disebut *dataset* pelatihan, di mana data akan dipelajari oleh algoritma klasifikasi. Proses ini dikenal sebagai pelatihan atau *training*. Pelatihan akan menghasilkan model yang mampu mengklasifikasi data baru berdasarkan pola atau karakteristik yang dipelajari dari *dataset* pelatihan[12]. Klasifikasi data menjadi kategori-kategori ini memungkinkan penggunaan model untuk prediksi atau pengambilan keputusan terhadap data baru yang belum pernah dilihat sebelumnya. Dengan menggunakan teknik-teknik seperti jaringan saraf tiruan atau metode pengklasifikasi lainnya, model dapat belajar dan meningkatkan akurasi prediksinya seiring bertambahnya data yang dipelajari.

Seiring dengan jumlah *spesies* tumbuhan herbal yang begitu banyak serta beragam, proses klasifikasi tumbuhan herbal tentunya menjadi tugas yang kompleks dan membutuhkan waktu yang relatif lama. Disamping hal tersebut, pada proses klasifikasi ini ditemukan tantangan *konvensional* yang cukup rumit. Selain keterbatasan pengetahuan botani yang dimiliki, tumbuhan-tumbuhan herbal juga sulit diidentifikasi secara akurat, mengingat terdapat kesamaan dalam morfologi di antara beberapa *spesies*, sehingga sulit untuk dibedakan secara kasat mata. Kesalahan klasifikasi terkadang berdampak buruk apabila berhubungan dengan komposisi racikan tumbuhan herbal dengan tujuan pengobatan, hal ini membutuhkan pendekatan yang cermat dalam penelitian dan identifikasi untuk memastikan kualitas dan keamanan penggunaan herbal dalam praktik medis tradisional maupun modern[13]. Berhubungan dengan tantangan kompleks dalam mengklasifikasi jenis tumbuhan herbal, perlu dikembangkan sebuah sistem otomatis yang mampu mengidentifikasi dan membedakan berbagai jenis tumbuhan berdasarkan citra.

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi tumbuhan herbal menggunakan metode *Convolutional Neural Network* (CNN). Diharapkan bahwa pendekatan ini dapat meningkatkan kemampuan dalam membedakan spesies tumbuhan herbal dan memprediksi manfaatnya dengan akurat. Dengan demikian, penelitian ini diharapkan memberikan kontribusi signifikan dalam mendukung penggunaan yang lebih *efektif* dan aman dari tumbuhan herbal sebagai alternatif pengobatan yang berkelanjutan dan alami. Tumbuhan herbal tidak hanya memiliki potensi dalam pengobatan tetapi juga sebagai sumber daya alam yang berharga. Dengan penggunaan yang tepat dan penelitian yang mendalam, tumbuhan herbal dapat menjadi solusi yang ekonomis dan berkelanjutan dalam menjaga kesehatan manusia dan lingkungan. Keberadaan tumbuhan herbal sebagai *alternatif* obat menjadi relevan dalam era modern ini, di mana banyak orang mulai memilih gaya hidup yang lebih sehat dan berkelanjutan.

Di samping itu, peran teknologi dalam mendukung pengembangan dan pemanfaatan tumbuhan herbal tidak dapat diabaikan. Teknologi klasifikasi, seperti CNN, menawarkan solusi untuk mengatasi tantangan kompleks dalam mengidentifikasi jenis tumbuhan dan memprediksi manfaatnya secara akurat. Melalui pendekatan ini,

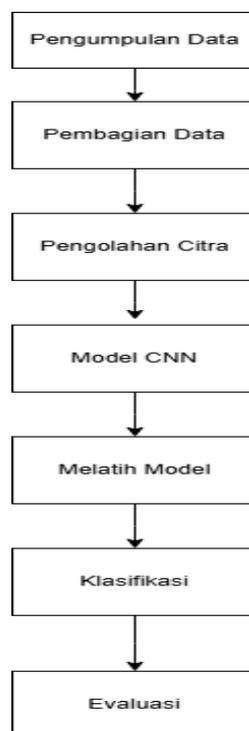
praktisi medis dapat lebih mudah mengakses informasi yang diperlukan untuk memilih pengobatan yang tepat berdasarkan karakteristik dan sifat-sifat aktif dari tumbuhan herbal. Dalam konteks yang lebih luas, pengembangan sistem klasifikasi tumbuhan herbal bukan hanya tentang meningkatkan efisiensi identifikasi, tetapi juga menghadirkan solusi yang lebih aman dan *efektif* dalam pengobatan tradisional. Dengan memanfaatkan keunggulan teknologi, seperti analisis visual yang mendalam, diharapkan bahwa penelitian ini akan membuka jalan bagi penggunaan tumbuhan herbal yang lebih terintegrasi dalam praktik kesehatan modern.

Beberapa peneliti terdahulu telah menggunakan CNN sebagai metode untuk identifikasi dan klasifikasi objek, seperti yang disajikan pada penelitian oleh [14] dan [15] mengenai klasifikasi daun tumbuhan herbal diperoleh nilai akurasi klasifikasi sebesar 71.3% dan 76%. *Convolutional Neural Network* adalah metode yang diakui sebagai metode terbaik untuk pemecahan masalah klasifikasi, deteksi dan pengenalan objek. Pada metode *Convolutional Neural Network* terdapat beberapa macam *arsitektur* yang umum dipergunakan pada pemecahan masalah klasifikasi objek. Penelitian selanjutnya oleh [6] Studi ini berhasil mencapai akurasi klasifikasi sebesar 96.2% untuk empat jenis daun herbal (daun kari, daun kelor, daun mint, dan daun sirih) menggunakan pendekatan *Convolutional Neural Network* dengan model VGG16 yang diadaptasi, menggunakan *learning rate* 0.001 dan dropout rate 50%. Penemuan ini menunjukkan potensi besar dalam mengimplementasikan teknologi pengolahan citra dan *deep learning* untuk meningkatkan *efisiensi* dan akurasi dalam klasifikasi daun herbal secara otomatis. Dan menurut penelitian oleh [16] ini menjelaskan hasil klasifikasi menunjukkan tingkat akurasi sebesar 65%. Akurasi tersebut terbilang cukup rendah disebabkan adanya kesamaan motif antara batik riau dengan batik lainnya, perbedaan terletak pada warna cerap batik Riau.

Pada penelitian ini, akan dirancang dan dibangun sebuah program yang menggunakan metode *Convolutional Neural Network* (CNN) dengan *arsitektur Sequential* untuk mengenali dan mengklasifikasi citra objek tumbuhan herbal.

## 2. METODE PENELITIAN

Pada penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) yang digunakan untuk mengklasifikasikan jenis tumbuhan herbal. Dalam metode penelitian, terdapat beberapa tahapan yang harus dilalui dengan seksama dan teliti guna memastikan kelancaran dan keberhasilan penelitian yang dilakukan. Tahapan-tahapan tersebut mencakup langkah-langkah yang meliputi pengumpulan data, pengolahan citra, membangun model, melatih model, klasifikasi, dan evaluasi. Adapun *algoritma* metodenya ada pada Gambar 1.



**Gambar 1.** Flowchart Metode Penelitian

## 2.1 Pengumpulan Data

Tahap pertama adalah melakukan pengumpulan data dilakukan dengan mengambil citra jenis tanaman herbal dimana terdiri atas 31 jenis tanaman herbal yaitu citra bawang merah, bawang putih, bayam, bunga peony, bunga telang, daun dambu biji, daun jarak, daun jeruk nipis, daun kemangi, daun kumis kucing, daun kunyit, daun mint, daun pandan, daun pepaya, daun sembung, daun sirih, daun sirsak, jahe, katuk, kelor, lidah buaya, saga, sambiloto, sambung nyawa, seledri, serai, tapak dara, teh hijau, *turnera ulmifolia*, *mulberry*, dengan jumlah total 6200 data Jenis Tanaman Herbal. Pengumpulan data ini dilakukan secara mandiri dimana menggunakan kamera smartphone Samsung A24 dengan kamera 50Mp. Data citra jenis tanaman herbal dapat dilihat pada Tabel 1.

**Tabel 1.** *Dataset* Jenis Tanaman Herbal

Jenis Tanaman	Jumlah Data
Bawang Merah	200
Bawang Putih	200
Bayam	200
Bunga Peony	200
Bunga Telang	200
Daun Jambu Biji	200
Daun Jarak	200
Daun Jeruk Nipis	200
Daun Kari	200
Daun Kemangi	200
Daun Kumis Kucing	200
Daun kunyit	200
Daun Mint	200
Daun Pandan	200
Daun Pepaya	200
Dauan Sembung	200
Daun Sirih	200
Daun Sirsak	200
Jahe	200
Katuk	200
Kelor	200
Lidah Buaya	200
Saga	200

Sambiloto	200
Sambung Nyawa	200
Seledri	200
Serai	200
Tapak Dara	200
Teh Hijau	200
Turnera Ulmifolia	200
Mulbery	200
<hr/>	
Total	6200
<hr/>	

## 2.2 Pembagian Data

Dalam analisis ini, data yang telah dikumpulkan dibagi menjadi tiga subset utama: data latih, data validasi, dan data tes. Data latih, yang berjumlah 4960 citra, digunakan untuk melatih model dalam mengenali dan mengklasifikasikan berbagai jenis tanaman herbal. Data ini memungkinkan model untuk belajar dan mengidentifikasi pola serta fitur dari setiap kelas tanaman. Sebanyak 621 citra dialokasikan sebagai data validasi, yang digunakan selama proses pelatihan untuk memantau performa model dan menghindari *overfitting* dengan melakukan penyesuaian yang diperlukan. Terakhir, data tes yang terdiri dari 124 citra digunakan untuk mengevaluasi kinerja akhir model setelah pelatihan selesai. Data tes memberikan penilaian tentang seberapa baik model dapat menggeneralisasi pada data yang benar-benar baru. Pembagian data ini memastikan bahwa model diuji dengan cara yang *efektif* dan dapat memberikan hasil yang akurat.

## 2.3 Pengolahan Citra

Tahap pengolahan yang dilakukan pertama adalah menentukan jumlah kelas dalam dataset. Dalam contoh ini, terdapat 31 kelas yang berbeda. Setelah itu, digunakan *ImageDataGenerator* untuk melakukan augmentasi data pada gambar. Tujuan dari augmentasi data adalah untuk membuat model lebih toleran terhadap variasi dalam dataset dan mencegah *overfitting*. *Augmentasi* dilakukan pada data latih dengan berbagai operasi seperti *rescale*, rotasi, pergeseran *horizontal* dan *vertikal*, pemotongan atau *shearing*, *zoom*, dan *flip horizontal*. Kemudian, tahap *rescale* dilakukan untuk mengubah intensitas piksel menjadi rentang 0 hingga 1. Selain itu, gambar-gambar dalam dataset diubah ukurannya menjadi 224x224 piksel dan setiap *batch* akan terdiri dari 64 gambar. Ini adalah ukuran target yang sesuai untuk input model *sequential*.

Pada data validasi, hanya dilakukan *rescale* untuk menjaga konsistensi skala dengan data latih. Untuk data pengujian, juga dilakukan *rescale*, tetapi gambar-gambar tidak diacak untuk memastikan *evaluasi* yang konsisten. Dengan *augmentasi* data, variasi dalam dataset pelatihan dapat ditingkatkan, sehingga membantu model dalam mempelajari *fitur-fitur* yang lebih umum dan mampu menghasilkan hasil yang lebih baik saat diterapkan pada data baru. Selain itu, ukuran *batch* untuk data pengujian ditentukan secara dinamis agar sesuai dengan panjang dataset pengujian, memastikan *efisiensi* selama proses *evaluasi*. Setelah *augmentasi* data dilakukan, jumlah total data yang dihasilkan untuk pelatihan tetap pada 4960 gambar, dengan validasi sebanyak 621 gambar, dan pengujian sebanyak 124 gambar. *Augmentasi* data tidak menambah jumlah gambar secara fisik tetapi meningkatkan variasi gambar yang digunakan selama proses pelatihan. Ini memberikan efek bahwa dataset pelatihan terasa lebih besar dan lebih bervariasi bagi model, sehingga membantu dalam peningkatan kinerja model secara keseluruhan.

## 2.4 Pembangunan Model

Kami menggunakan sebuah model *Sequential Convolutional Neural Network* (CNN) dengan arsitektur berikut: pertama, lapisan *Conv2D* dengan 32 filter berukuran (3, 3) dan fungsi aktivasi ReLU, diikuti oleh lapisan *MaxPooling2D* dengan ukuran pool (2, 2) untuk mengurangi dimensi spasial. Kemudian, kami menambahkan lapisan *Conv2D* kedua dengan 64 filter (3, 3) dan fungsi aktivasi ReLU, diikuti lagi oleh *MaxPooling2D*. Data yang dihasilkan kemudian diluruskan (*flattened*) dan dimasukkan ke dalam lapisan *Dense* dengan 128 *neuron* dan

fungsi aktivasi ReLU. Untuk mengurangi *overfitting*, kami menerapkan *dropout* dengan tingkat *dropout* sebesar 0.5. Lapisan output menggunakan *Dense* dengan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas, sesuai dengan jumlah kelas yang ada dalam *dataset*. Model di-*train* menggunakan *categorical crossentropy* sebagai fungsi *loss*, dioptimalkan menggunakan *Adam optimizer*, dan *evaluasi performa* menggunakan metrik akurasi.

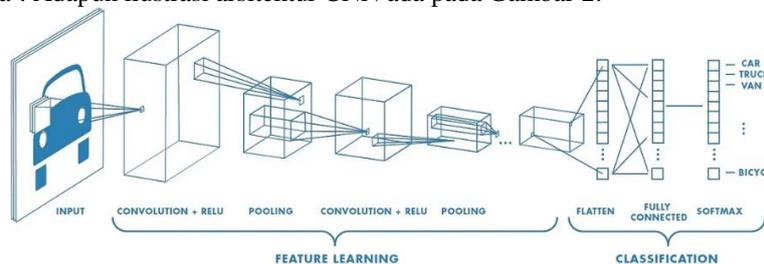
## 2.5 Pelatihan Model

Setelah membangun model *Sequential Convolutional Neural Network* (CNN), model dilatih menggunakan *generator* untuk data lath dan data validasi. Dalam setiap *epoch*, langkah – langkah pelatihan dihitung berdasarkan jumlah sampel data latih dibagi dengan Dalam setiap *epoch*, langkah-langkah pelatihan dihitung berdasarkan jumlah sampel data latih 4960 dibagi dengan ukuran *batch* yang telah ditetapkan sebesar 64, untuk memaksimalkan *efisiensi* dalam pengolahan data. *Evaluasi* terhadap data *validasi* dilakukan setelah setiap *epoch*, dengan langkah-langkah *validasi* yang disesuaikan berdasarkan jumlah sampel data validasi 621 dibagi dengan ukuran *batch* yang sama. Proses pelatihan dilakukan selama 10 *epoch* untuk mengoptimalkan kinerja model terhadap *dataset* yang tersedia.

Model ini dioptimalkan menggunakan *Adam optimizer* dengan fungsi *loss categorical crossentropy* untuk mencapai konvergensi yang optimal. Metrik akurasi digunakan untuk mengukur kinerja model dalam mengklasifikasikan data. Pendekatan ini bertujuan untuk memperkuat kemampuan model dalam mengenali pola-pola visual yang kompleks dalam *dataset*, dengan fokus pada peningkatan akurasi dan generalisasi pada data validasi. Dengan melalui beberapa *epoch*, model CNN dapat secara *efektif* mengenali dan mengklasifikasikan gambar-gambar dalam *dataset*. Setelah proses pelatihan data, hasil yang diperoleh disimpan untuk dilakukan proses pengujian data.

## 2.6 Klasifikasi

Klasifikasi dalam penelitian ini menggunakan metode CNN untuk membandingkan keakuratan prediksi dengan data citra. *Convolutional Neural Network* (CNN) berperan sebagai pendeteksi *fitur hierarkis* yang terinspirasi secara biologis, mampu mempelajari dan mengidentifikasi objek bahkan yang bersifat abstrak. CNN digunakan untuk mengklasifikasi data berlabel dengan menggunakan metode pembelajaran terawasi. Proses pengembangan model CNN umumnya melibatkan empat komponen utama: *layer konvolusi*, *layer pooling*, fungsi aktivasi, dan *layer fully connected*. Adapun ilustrasi arsitektur CNN ada pada Gambar 2.



**Gambar 2.** Ilustrasi Struktur *Convolutional Neural Network*

Sumber : [Arsitektur Cnn - Homecare24](#)

### a. Convolution Layer

*Convolution layer* termasuk unsur terpenting dari CNN yang bertujuan melakukan ekstraksi terhadap fitur citra gambar dengan bobot konvolusi yang berbeda. Setelah melakukan konvolusi secara berulang maka dapat mengekstrak set fitur map dari citra gambar masukan. *Feature map* pada *convolutional layer*.

$$output = \frac{W - N + 2P}{s} + 1 \quad (1)$$

Keterangan:

W = panjang/tinggi *input*

N = panjang/tinggi *filter*

P = *zero padding*

S = *stride*

### b. Pooling Layers

Penggunaan *pooling layers* dilakukan sebagai upaya mengurangi jumlah parameter yang dapat dilatih agar meminimalisir waktu pada proses komputasi. Terdapat dua teknik *pooling*, yaitu *max pooling* dan *average pooling*. *Max pooling* bertujuan dalam menemukan nilai maksimum dalam suatu area,

sedangkan *average pooling* untuk menemukan rata-rata dari *fitur* dari suatu area. Persamaan *pooling layer* yaitu :

$$W2 = (W1-F + 2P) / S + 1 = H2 \quad (2)$$

$$D2 = D1 \quad (3)$$

Keterangan:

W1 = panjang/tinggi *input*

N = panjang/tinggi *filter*

P = *zero padding*

S = *stride*

W2 = panjang/tinggi output setelah *pooling*

D1 = kedalaman *input*

D2 = Kedalaman *output* (tetap sama)

c. Fungsi aktivasi

Fungsi aktivasi merupakan suatu fungsi yang memungkinkan jaringan mengubah data input menjadi dimensi yang lebih tinggi untuk pengklasifikasian. Fungsi *sigmoid* merupakan fungsi aktivasi dari CNN yang diaplikasikan untuk mengganti nilai input *xx* menjadi 0 dan 1 menggunakan bentuk distribusi fungsi, pada persamaan (4). Adapun fungsi ReLU secara umum dimanfaatkan sebagai fungsi pengganti yang menjaga karakteristik model *linear* seperti pada persamaan (4).

$$f(x) = 1 / (1 + e^{-x}) \quad (4)$$

$$f(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (5)$$

Keterangan:

$f(x) = 1 / (1 + e^{-x})$  : fungsi sigmoid, rentang (0, 1)

$f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$  : fungsi tanh (Tangen Hiperbolik), rentang (-1, 1)

d. *Fully Connected Layer*

*Fully Connected Layer* merupakan sebuah lapisan yang menghubungkan setiap neuron yang mempunyai lintasan yang sama dan mengklasifikasikan citra gambar sesuai dengan citra fitur yang telah terekstraksi, seperti pada persamaan (6).

$$y = Wx + b \quad (6)$$

Keterangan :

W = matriks bobot (*weights*)

x = vektor input

b = vektor bias

y = output *layer fully connected*

## 2.7 Evaluasi

Dalam melakukan proses klasifikasi model label kelas menggunakan beberapa matriks diantaranya, *accuracy*, *precision*, *recall*, dan *f1-score*. Setiap baris matriks mewakili kelas dari data aktual, kolom mewakili kelas data prediksi begitu juga dengan sebaliknya. Sebelum menggunakan matriks terlebih dahulu mendefinisikan *True Negative* (TN) sebagai data aktual *negatif* yang diprediksi menjadi *negatif*, *False Negative* (FN) sebagai data aktual *positif* yang diprediksi menjadi *negatif*, *False Positive* (FP) sebagai data aktual *negatif* yang diprediksi menjadi *positif*, *True Positive* (TP) sebagai data aktual *positif* yang diprediksi menjadi *positif*.

1. *Accuracy*

*Accuracy* merupakan nilai proporsi secara keseluruhan dalam mendefinisikan tingkat ketepatan pada proses klasifikasi data dengan bentuk persentase. Untuk menghitungnya dapat menggunakan rumus sebagai berikut :

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (7)$$

2. *Precision*

*Precision* adalah metrik yang digunakan untuk mengukur sejauh mana model klasifikasi memberikan prediksi yang benar secara positif.. Untuk menghitungnya dapat menggunakan rumus sebagai berikut :

$$precision = \frac{TP}{TP+FP} \quad (8)$$

3. *Recall*

*Recall* adalah metrik yang digunakan untuk mengukur sejauh mana model klasifikasi dapat mengidentifikasi semua kasus positif yang sebenarnya.. Untuk menghitungnya dapat menggunakan rumus sebagai berikut :

$$Recall = \frac{TP}{TP+FN} \quad (9)$$

4. *F1-Score*

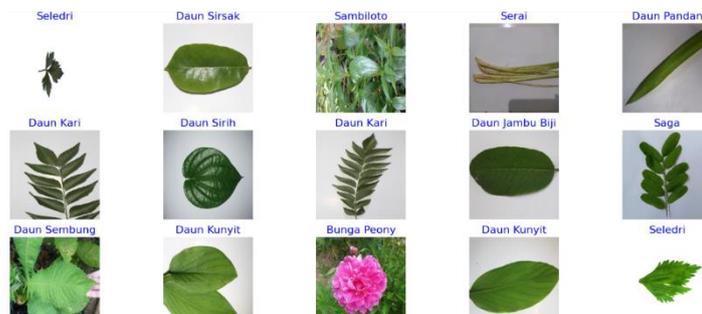
*F1-Score* adalah nilai dari perhitungan precision dan recall. Untuk menghitungnya dapat menggunakan rumus sebagai berikut :

$$F1 - Score = \frac{TP}{TP + \frac{1}{2}(FP+FN)} \quad (10)$$

### 3. HASIL DAN PEMBAHASAN

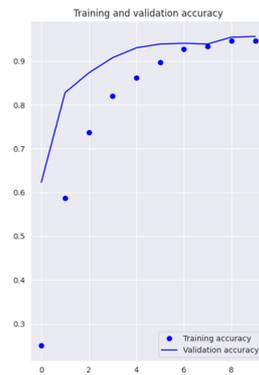
#### 3.1 Hasil

Dalam penelitian ini, kami menerapkan berbagai teknik *augmentasi* data untuk meningkatkan keberagaman dataset latih yang digunakan dalam model *Convolutional Neural Network (CNN)* dengan *arsitektur sequential*. Proses *augmentasi* dimulai dengan *rescaling*, yang mengubah intensitas piksel gambar menjadi rentang 0 hingga 1 untuk menjaga konsistensi skala input. Kami juga menerapkan *rotasi*, yang memutar gambar pada sudut acak untuk memperkenalkan variasi *orientasi*; pergeseran (*shifting*), yang menggeser gambar secara *horizontal* atau *vertikal* guna melatih model pada posisi objek yang berbeda; pemotongan (*cropping*), yang memotong bagian-bagian tertentu dari gambar untuk fokus pada area yang berbeda; *zoom*, yang memperbesar bagian spesifik dari gambar untuk menyoroti detail kecil; serta *flipping*, yang membalik gambar secara *horizontal* untuk menciptakan versi *mirror* dari gambar asli. Setiap teknik *augmentasi* ini dirancang untuk menghasilkan citra berukuran 224x224 piksel, yang secara signifikan meningkatkan keberagaman dataset dan kualitas pelatihan. Hasil *augmentasi* data ini tidak hanya memperluas variasi dalam dataset, tetapi juga meningkatkan kemampuan model dalam mengenali pola *visual* yang kompleks dan mengurangi resiko *overfitting*. Contoh dari hasil *augmentasi* data dapat dilihat pada Gambar 3, yang menunjukkan variasi gambar yang dihasilkan melalui proses *augmentasi* tersebut.



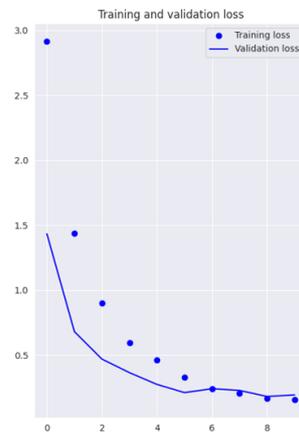
Gambar 3. Hasil Augmentsi Citra

Setelah melalui proses *augmentasi* data pada citra daun tanaman obat, tahapan berikutnya adalah pelatihan model menggunakan *optimizer Adam*, *fungsi loss*, dan metrik akurasi. Pelatihan dilakukan dalam 10 *epoch* dengan memanfaatkan 4960 gambar untuk data latih, 621 gambar untuk data validasi, dan 124 gambar untuk data uji. Pada setiap *epoch*, model melakukan prediksi terhadap data latih dan validasi untuk mengoptimalkan parameter internalnya, memperbaiki kinerja, dan meningkatkan kemampuan model dalam mengenali pola visual yang mewakili berbagai jenis daun tanaman obat secara lebih akurat. Selama proses pelatihan, dihasilkan juga grafik yang memberikan visualisasi *komprehensif* tentang performa model sepanjang tiap *epoch*. Grafik ini memberikan pemahaman yang mendalam mengenai perubahan dalam akurasi dan penurunan fungsi kerugian dari *epoch* ke *epoch*. Tujuannya adalah untuk memantau dengan cermat kemajuan model secara *real-time*, serta untuk mengidentifikasi apakah model sudah mencapai titik konvergensi atau masih memerlukan penyesuaian lebih lanjut. Dengan pendekatan pemantauan yang sistematis ini, kami dapat melakukan optimalisasi lebih lanjut terhadap model, sehingga memastikan bahwa model yang dikembangkan mampu memberikan klasifikasi jenis daun tanaman obat dengan tingkat akurasi yang optimal dan dapat diandalkan. Adapun grafik *loss* dan *accuracy* hasil *training* dapat dilihat pada Gambar 4 dan Gambar 5.



Gambar 4. Grafik Accuracy

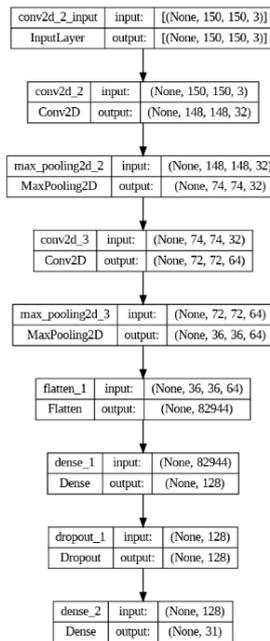
Dari Gambar 4 terlihat grafik ini menunjukkan bagaimana akurasi model berkembang selama pelatihan dan validasi. *Representasi* dengan titik biru menunjukkan akurasi model pada data pelatihan. Dari awal *epoch* 1 hingga akhir *epoch* 10, akurasi model meningkat secara konsisten dari sekitar 25% menjadi sekitar 95%. Sedangkan, *Representasi* dengan garis biru menunjukkan akurasi model pada data validasi. Ini adalah cara untuk mengukur kinerja model pada data yang belum pernah dilihat sebelumnya. Akurasi pada data validasi juga meningkat dari sekitar 62% pada awal pelatihan menjadi sekitar 95% pada epoch terakhir.



Gambar 5. Grafik Loss

Pada Gambar 5 terlihat bahwa grafik ini menunjukkan bagaimana kerugian model berkembang selama pelatihan dan validasi. Kerugian atau *loss* adalah nilai yang dihitung selama pelatihan yang mewakili seberapa buruk model melakukan prediksi pada titik waktu tertentu. *Representasi* dengan titik biru menunjukkan kerugian model pada data pelatihan. Nilai kerugian secara konsisten menurun dari sekitar 2.9 pada awal pelatihan menjadi kurang dari 0.2 pada akhir pelatihan epoch 10. Sedangkan, *Representasi* dengan garis biru menunjukkan kerugian model pada data validasi. Seperti akurasi validasi, kerugian validasi juga menunjukkan penurunan yang signifikan dari sekitar 1.4 menjadi sekitar 0.2 pada epoch terakhir.

Untuk pemodelan, kami menggunakan *arsitektur Sequential* dari *TensorFlow Keras* yang terdiri dari beberapa lapisan konvolusi dan *pooling*. Model ini dimulai dengan lapisan *Conv2D* berukuran 32 filter dengan kernel (3, 3) dan fungsi aktivasi ReLU, diikuti oleh lapisan *MaxPooling2D* dengan ukuran pool (2, 2). Kemudian, lapisan konvolusi kedua dengan 64 filter dan kernel (3, 3) serta fungsi aktivasi ReLU ditambahkan, diikuti oleh lapisan *MaxPooling2D* yang sama. Lapisan-lapisan ini diikuti oleh lapisan *Flatten* untuk meratakan hasil konvolusi menjadi vektor satu dimensi, yang kemudian dihubungkan ke lapisan *Dense* dengan 128 unit dan fungsi aktivasi ReLU. Kami juga menambahkan lapisan *Dropout* dengan tingkat drop sebesar 0.5 untuk mencegah *overfitting*. Lapisan terakhir adalah lapisan *Dense* dengan jumlah unit yang sama dengan jumlah kelas dan fungsi aktivasi softmax untuk menghasilkan probabilitas klasifikasi. Model dikompilasi menggunakan fungsi *loss categorical\_crossentropy*, *optimizer Adam*, dan metrik akurasi.



Gambar 6. Hasil Arsitektur Model

Gambar 6 di atas mengilustrasikan penerapan fungsi aktivasi dalam melatih model CNN untuk klasifikasi jenis tanaman herbal berdasarkan citra. Fungsi aktivasi yang digunakan adalah *Rectified Linear Unit* (ReLU). Pelatihan model CNN ini melibatkan total 10.640.351 parameter. Jumlah parameter ini didapat dari perhitungan pada setiap lapisan model. Pada lapisan *Conv2D* pertama, terdapat 896 parameter yang terdiri dari kernel 3x3 dengan 3 *channel input* dan 32 filter, ditambah 32 parameter bias. Lapisan *Conv2D* kedua memiliki 18.496 parameter yang terdiri dari kernel 3x3 dengan 32 *channel input* dan 64 filter, ditambah 64 parameter bias. Lapisan *Dense* pertama memiliki 10.616.320 parameter yang terdiri dari 82.944 input yang dikalikan dengan 128 unit *neuron*, ditambah 128 parameter bias. Terakhir, lapisan *Dense* kedua memiliki 3.999 parameter yang terdiri dari 128 input yang dikalikan dengan 31 unit *neuron*, ditambah 31 parameter bias. Jumlah parameter yang besar ini membuat proses perhitungan sangat kompleks dan memerlukan waktu serta tenaga yang signifikan jika dilakukan secara manual oleh manusia. Namun, mesin mampu menyelesaikannya dengan cepat dan *efisien*.

Akurasi validasi sebesar 92,5% menunjukkan bahwa ketika model diuji pada dataset yang terpisah dan belum pernah dilihat selama proses pelatihan atau validasi, model tersebut dapat memprediksi hasil dengan benar sebanyak 92,5% dari waktu yang ada. Ini adalah hasil yang memuaskan dan mengindikasikan bahwa model berfungsi dengan baik serta mampu menggeneralisasi data baru yang belum pernah dilihat sebelumnya dengan baik.

```

Epoch 1/10
77/77 [=====] - 1650s 21s/step - loss: 2.9161 - accuracy: 0.2502 - val_loss: 1.4334 - val_accuracy: 0.6233
Epoch 2/10
77/77 [=====] - 633s 8s/step - loss: 1.4354 - accuracy: 0.5872 - val_loss: 0.6808 - val_accuracy: 0.8281
Epoch 3/10
77/77 [=====] - 634s 8s/step - loss: 0.8986 - accuracy: 0.7373 - val_loss: 0.4692 - val_accuracy: 0.8733
Epoch 4/10
77/77 [=====] - 642s 8s/step - loss: 0.5958 - accuracy: 0.8201 - val_loss: 0.3648 - val_accuracy: 0.9080
Epoch 5/10
77/77 [=====] - 637s 8s/step - loss: 0.4604 - accuracy: 0.8623 - val_loss: 0.2742 - val_accuracy: 0.9306
Epoch 6/10
77/77 [=====] - 640s 8s/step - loss: 0.3276 - accuracy: 0.8973 - val_loss: 0.2113 - val_accuracy: 0.9392
Epoch 7/10
77/77 [=====] - 630s 8s/step - loss: 0.2420 - accuracy: 0.9275 - val_loss: 0.2410 - val_accuracy: 0.9410
Epoch 8/10
77/77 [=====] - 600s 8s/step - loss: 0.2076 - accuracy: 0.9340 - val_loss: 0.2281 - val_accuracy: 0.9392
Epoch 9/10
77/77 [=====] - 619s 8s/step - loss: 0.1670 - accuracy: 0.9467 - val_loss: 0.1812 - val_accuracy: 0.9549
Epoch 10/10
77/77 [=====] - 630s 8s/step - loss: 0.1567 - accuracy: 0.9467 - val_loss: 0.1935 - val_accuracy: 0.9566
  
```

Gambar 7. Hasil Pelatihan Model

Pada gambar 7, proses pelatihan model CNN dilakukan selama 10 *epoch*, dengan detail sebagai berikut:

1. *Epoch 1/10*: Pada *epoch* pertama, model memulai dengan nilai *loss* sebesar 2.9161 dan akurasi 0.2502. Setelah melewati proses pelatihan pertama, nilai validasi *loss* turun menjadi 1.4334 dan akurasi validasi meningkat menjadi 0.6233.

2. *Epoch 2/10*: Pada *epoch* kedua, nilai *loss* pada data pelatihan menurun drastis menjadi 1.4354 dengan akurasi meningkat menjadi 0.5872. Nilai validasi *loss* juga menurun signifikan menjadi 0.6808 dengan akurasi validasi mencapai 0.8281.
3. *Epoch 3/10*: Pada *epoch* ketiga, model terus menunjukkan peningkatan dengan nilai *loss* menurun menjadi 0.8986 dan akurasi pelatihan mencapai 0.7373. Nilai validasi *loss* turun menjadi 0.4692 dan akurasi validasi meningkat menjadi 0.8733.
4. *Epoch 4/10*: Pada *epoch* keempat, nilai *loss* pelatihan turun lebih lanjut menjadi 0.5958 dengan akurasi meningkat menjadi 0.8201. Nilai validasi *loss* turun menjadi 0.3648 dan akurasi validasi mencapai 0.9080.
5. *Epoch 5/10*: Pada *epoch* kelima, nilai *loss* pada data pelatihan mencapai 0.4604 dengan akurasi 0.8623. Nilai validasi *loss* turun menjadi 0.2742 dan akurasi validasi meningkat menjadi 0.9306.
6. *Epoch 6/10*: Pada *epoch* keenam, nilai *loss* pelatihan turun menjadi 0.3276 dengan akurasi meningkat menjadi 0.8973. Nilai validasi *loss* turun menjadi 0.2113 dan akurasi validasi mencapai 0.9392.
7. *Epoch 7/10*: Pada *epoch* ketujuh, nilai *loss* pelatihan mencapai 0.2420 dengan akurasi 0.9275. Nilai validasi *loss* sedikit meningkat menjadi 0.2410 namun akurasi validasi tetap tinggi di 0.9410.
8. *Epoch 8/10*: Pada *epoch* kedelapan, nilai *loss* pelatihan turun lebih lanjut menjadi 0.2076 dengan akurasi meningkat menjadi 0.9340. Nilai validasi *loss* turun menjadi 0.2281 dengan akurasi validasi tetap tinggi di 0.9392.
9. *Epoch 9/10*: Pada *epoch* kesembilan, nilai *loss* pelatihan mencapai 0.1670 dengan akurasi 0.9467. Nilai validasi *loss* turun menjadi 0.1812 dan akurasi validasi meningkat menjadi 0.9549.
10. *Epoch 10/10*: Pada *epoch* terakhir, nilai *loss* pelatihan menurun lebih lanjut menjadi 0.1567 dengan akurasi tetap tinggi di 0.9467. Nilai validasi *loss* sedikit meningkat menjadi 0.1935 namun akurasi validasi mencapai 0.9566.

Perkembangan nilai *loss* dan akurasi ini menunjukkan bahwa model kami semakin baik dalam memprediksi kelas dari data pelatihan dan validasi seiring bertambahnya jumlah *epoch*. Penurunan yang konsisten pada nilai *loss* dan peningkatan pada akurasi validasi menunjukkan bahwa model tidak hanya belajar dari data pelatihan tetapi juga mampu menggeneralisasi dengan baik pada data validasi, yang merupakan indikasi dari model yang *robust* dan *efektif*.

Hasil dari *classification report* menunjukkan kinerja model dalam mengidentifikasi berbagai jenis daun tanaman herbal dengan baik. Model ini mencapai akurasi keseluruhan sebesar 93%, yang berarti dari 124 gambar daun yang diuji, 115 gambar diklasifikasikan dengan benar. Setiap metrik, seperti *precision*, *recall*, dan *f1-score*, memberikan gambaran mengenai keakuratan dan konsistensi model dalam mengklasifikasikan setiap jenis daun. Secara rinci, beberapa jenis daun seperti Daun Kari, Daun Kemangi, Daun Pepaya, dan Daun Sirih menunjukkan *precision* yang tinggi hingga mencapai 1.00, yang menunjukkan bahwa model ini hampir tidak membuat kesalahan ketika mengidentifikasi jenis-jenis daun tersebut. Misalnya, Daun Kari memiliki *f1-score* sebesar 1.00, menunjukkan keseimbangan yang baik antara *precision* dan *recall*. Di sisi lain, Daun Mint dan Teh Hijau memiliki *f1-score* yang lebih rendah, masing-masing 0.91 dan 0.80, menunjukkan bahwa model ini sedikit kurang akurat dalam mengidentifikasi daun-daun tersebut. Hasil lengkap dari *classification report* adalah sebagai berikut:

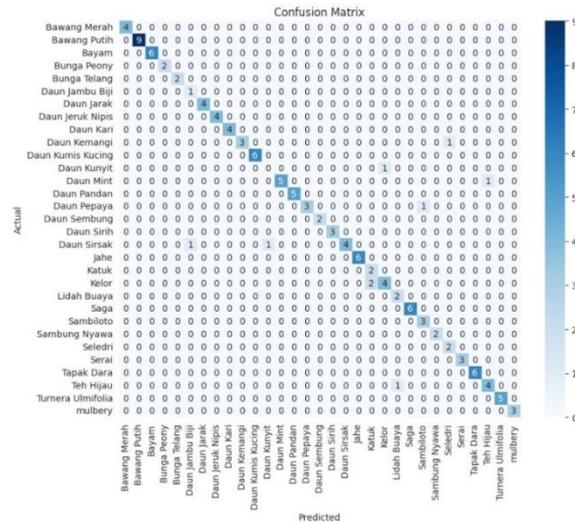
**Tabel 2.** Hasil *Classification Report*

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Bawang Merah	1.00	1.00	1.00	4
Bawang Putih	1.00	1.00	1.00	9
Bayam	1.00	1.00	1.00	6
Bunga Peony	1.00	1.00	1.00	2
Bunga Telang	1.00	1.00	1.00	2
Daun Jambu Biji	0.50	1.00	0.67	1
Daun Jarak	1.00	1.00	1.00	4
Daun Jeruk Nipis	1.00	1.00	1.00	4
Daun Kari	1.00	1.00	1.00	4
Daun Kemangi	1.00	0.75	0.86	4
Daun Kumis Kucing	1.00	1.00	1.00	6
Daun Kunyit	0.00	0.00	0.00	1
Daun Mint	1.00	0.83	0.91	6
Daun Pandan	1.00	1.00	1.00	5
Daun Pepaya	1.00	0.75	0.86	4
Daun Sembung	1.00	1.00	1.00	2
Daun Sirih	1.00	1.00	1.00	3
Daun Sirsak	1.00	0.67	0.80	6

Jahe	1.00	1.00	1.00	6
Katuk	0.50	1.00	0.67	2
Kelor	0.80	0.67	0.73	6
Lidah Buaya	0.67	1.00	0.80	2
Saga	1.00	1.00	1.00	6
Sambiloto	0.75	1.00	0.86	3
Sambung Nyawa	1.00	1.00	1.00	2
Seledri	0.67	1.00	0.80	2
Serai	1.00	1.00	1.00	3
Tapak Dara	1.00	1.00	1.00	6
Teh Hijau	0.80	0.80	0.80	5
Turnera Ulmifolia	1.00	1.00	1.00	5
Mulbery	1.00	1.00	1.00	3
<i>Accuracy</i>			0.93	124
<i>Macro avg</i>	0.89	0.92	0.89	124
<i>Weighted avg</i>	0.95	0.93	0.93	124

Secara keseluruhan, hasil ini menunjukkan bahwa model *Convolutional Neural Network* (CNN) yang digunakan mampu menggeneralisasi dengan baik terhadap data baru yang belum pernah dilihat sebelumnya, dengan performa yang kuat dalam sebagian besar kategori daun. Dengan tingkat akurasi keseluruhan sebesar 93%, model ini menunjukkan keefektifan dalam mengklasifikasikan jenis-jenis tanaman herbal berdasarkan citra. Tingginya nilai *precision*, *recall*, dan *F1-score* dalam banyak kategori mengindikasikan bahwa model ini tidak hanya akurat dalam identifikasinya tetapi juga konsisten dalam kinerjanya. Analisis lebih mendalam pada hasil menunjukkan bahwa untuk beberapa kategori tanaman seperti Daun Jambu Biji, Katuk, dan Kelor, terdapat sedikit penurunan pada nilai *recall* dan *precision*, yang dapat menjadi indikasi perlunya lebih banyak data atau variasi dalam dataset untuk meningkatkan kinerja pada kategori-kategori tersebut. Meskipun demikian, banyak kategori lain seperti Bawang Merah, Bawang Putih, Bayam, dan Bunga Telang menunjukkan hasil sempurna dengan nilai *precision*, *recall*, dan *F1-score* yang mencapai 1.00, menunjukkan bahwa model ini sangat *efektif* dalam mengenali tanaman – tanaman herbal tersebut.

Keberhasilan model ini dalam mengidentifikasi berbagai jenis tanaman herbal membuka peluang besar dalam aplikasi teknologi *deep learning* di bidang botani dan pertanian. Sistem ini tidak hanya dapat membantu dalam penelitian ilmiah dan klasifikasi tanaman, tetapi juga dapat diterapkan dalam sistem monitoring pertanian pintar, yang mempermudah petani dalam mengenali dan mengelola tanaman mereka dengan lebih *efisien*. Selain itu, hasil penelitian ini menunjukkan bahwa penggunaan teknik augmentasi data, seperti *rescaling*, rotasi, *shifting*, *cropping*, dan *flipping*, telah berhasil meningkatkan keragaman dan kualitas dataset, yang pada gilirannya meningkatkan kinerja model. Potensi besar yang ditunjukkan oleh model ini dalam klasifikasi tanaman herbal juga bisa diterapkan dalam pengembangan aplikasi *mobile* untuk identifikasi tanaman, yang dapat digunakan oleh masyarakat umum dan profesional di bidang botani. Dengan demikian, hasil penelitian ini tidak hanya memiliki kontribusi ilmiah tetapi juga potensi aplikatif yang luas dalam dunia nyata, menjadikan teknologi *deep learning* sebagai alat yang semakin penting dalam berbagai aspek kehidupan.



Gambar 8. Confusion Matrix

Gambar 8 di atas menampilkan matriks kebingungan atau *confusion matrix* yang dihasilkan dari pengujian model CNN pada dataset gambar jenis tanaman herbal. Matriks kebingungan ini memberikan gambaran visual tentang kinerja model dalam mengklasifikasikan berbagai jenis tanaman herbal. Setiap baris pada matriks ini mewakili kelas sebenarnya atau *actual*, sedangkan setiap kolom mewakili kelas yang diprediksi oleh model (*predicted*). Angka pada sel menunjukkan jumlah contoh yang terklasifikasi pada kombinasi kelas tertentu. Misalnya, angka 4 pada baris Bawang Merah dan kolom Bawang Merah menunjukkan bahwa semua 4 contoh gambar bawang merah diklasifikasikan dengan benar oleh model. Beberapa poin penting yang dapat diambil dari matriks kebingungan ini adalah:

1. Model menunjukkan kinerja yang sangat baik dalam mengklasifikasikan banyak jenis daun, seperti Bawang Putih, Bayam, Daun Kari, Daun Kumis Kucing, dan Tapak Dara, yang semua contoh dari jenis-jenis ini diklasifikasikan dengan benar.
2. Untuk beberapa jenis daun, seperti Daun Kemangi dan Daun Pepaya, model masih menunjukkan kesalahan dalam klasifikasi, yang tercermin dari beberapa nilai di luar diagonal utama. Misalnya, dari 4 contoh Daun Kemangi, 1 di antaranya diklasifikasikan sebagai Daun Sirsak.
3. Ada juga beberapa jenis daun yang hanya memiliki satu contoh dalam dataset, seperti Daun Jambu Biji dan Daun Kunyit, yang keduanya diklasifikasikan dengan benar oleh model.

Secara keseluruhan, matriks kebingungan ini mengindikasikan bahwa model CNN yang digunakan mampu mengklasifikasikan sebagian besar jenis daun dengan baik, dengan sedikit kesalahan klasifikasi pada beberapa jenis daun tertentu. Hasil ini mendukung validitas dan kemampuan model dalam melakukan klasifikasi jenis tanaman herbal berdasarkan citra.

#### 4. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi tumbuhan herbal menggunakan *Convolutional Neural Network* (CNN) untuk meningkatkan kemampuan dalam membedakan spesies tumbuhan herbal dan memprediksi manfaatnya secara akurat. Dengan menggunakan *dataset* awal yang berisi 6200 gambar dari 31 jenis tumbuhan herbal, kami berhasil mengembangkan model CNN berbasis *arsitektur Sequential* yang mencapai akurasi sebesar 92.74%. Tujuan utama penelitian ini adalah untuk membangun sistem klasifikasi yang *efektif*, dan hasilnya menunjukkan bahwa pendekatan yang diterapkan memenuhi tujuan tersebut dengan baik. Teknik *augmentasi* data, seperti rotasi, pergeseran, pemotongan, dan *flipping*, telah diterapkan untuk memperluas variasi data pelatihan. Meskipun jumlah gambar fisik tetap 4960 untuk pelatihan, 621 untuk validasi, dan 124 untuk pengujian, *augmentasi* data meningkatkan keragaman pelatihan yang membantu model dalam menggeneralisasi data uji yang belum pernah dilihat sebelumnya.

Hasil penelitian menunjukkan bahwa model yang dikembangkan efektif dalam mengklasifikasikan berbagai jenis tumbuhan herbal, dengan nilai *precision* dan *recall* yang tinggi pada banyak kategori, termasuk nilai 1.00 untuk beberapa jenis tumbuhan. Namun, beberapa kategori, seperti daun jambu biji dan katuk, menunjukkan variasi

dalam *precision* dan *recall*. Ini menunjukkan bahwa model mungkin memerlukan dataset yang lebih *variatif* atau tambahan data untuk meningkatkan kinerja pada kategori-kategori tersebut. Masalah ini menggarisbawahi perlunya pengumpulan data tambahan dan *eksplorasi* teknik yang lebih canggih untuk meningkatkan akurasi pada kategori yang kurang optimal.

Untuk penelitian mendatang, kami merekomendasikan *eksplorasi arsitektur* CNN yang lebih kompleks seperti VGG16 atau *ResNet* serta evaluasi terhadap fungsi aktivasi dan *optimizer* yang lebih beragam. Penelitian ini membuktikan bahwa pendekatan berbasis CNN *efektif* untuk pengenalan gambar daun tanaman herbal dan dapat digunakan dalam aplikasi identifikasi otomatis tanaman herbal. Dengan terus memperbaiki metodologi ini, kami berharap dapat mendukung penggunaan tumbuhan herbal sebagai alternatif pengobatan yang berkelanjutan dan *efektif*, serta memperluas aplikasi dalam *konservasi* tanaman dan *identifikasi* obat alami.

## UCAPAN TERIMAKASIH

Peneliti mengucapkan terima kasih yang sebesar-besarnya kepada semua peneliti yang terlibat dalam penelitian ini. Dedikasi dan kontribusi setiap peneliti dalam tim telah memainkan peran krusial dalam pencapaian hasil yang signifikan ini. Peneliti juga mengucapkan terima kasih kepada kolega-kolega dan institusi yang telah memberikan dukungan penuh dalam proses ini. Kerjasama ini bukan hanya menghasilkan pengetahuan baru, tetapi juga memperkuat jalinan kolaborasi di antara kita.

## REFERENCES

- [1] A. Zalvadila, L. Syafie, and H. Darwis, "Klasifikasi Penyakit Tanaman Bawang Merah Menggunakan Metode SVM dan CNN," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 8, no. 3, pp. 255–260, 2023, doi: 10.30591/jpit.v8i3.5341.
- [2] R. Prabowo, A. Roudhoh, and A. Afifah, "Klasifikasi Image Tumbuhan Obat Sirih dan Binahong Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Komputasi*, vol. 10, no. 2, pp. 48-54, 2022. doi: 10.23960/komputasi.v10i2.3178.
- [3] N. Putu Dita Ariani Sukma Dewi, M. Windu Antara Kesiman, I. Made Gede Sunarya, I. Gusti Ayu Agung Diatri Indradewi, and I. Gede Andika, "Klasifikasi Jenis Daun Tumbuhan Herbal Berdasarkan Lontar Usada Taru Pramana Menggunakan CNN," *Techno. Com*, vol. 23, no. 1, pp. 271, Feb. 2024. doi: 10.62411/tc.v23i1.9510
- [4] Haryono, K. Anam, and A. Saleh, "Autentikasi Daun Herbal Menggunakan Convolutional Neural Network dan Raspberry Pi," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 9, no. 3, pp. 278-286, 2020. doi: <https://doi.org/10.22146/v9i3.302>.
- [5] S. Adiningsi and R. A. Saputra, "Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model Vgg16," *Jurnal Informatika Polinema*, vol. 9, no. 4, pp. 451–460, 2023, doi: 10.33795/jip.v9i4.1420.
- [6] M. H. Ahmad, M. Hana, T. Ghazi Pratama, and H. Aulida, "Klasifikasi Empat Jenis Daun Herbal Menggunakan Metode Convolutional Neural Network," *Jurnal Ilmu Komputer dan Matematika*, vol. 4, no. 2, pp. 69-76, 2023.
- [7] D. Harefa, S. Nias Selatan, K. Kunci, and P. Tanaman Obat Keluarga, "Pemanfaatan Hasil Tanaman Sebagai Tanaman Obat Keluarga (TOGA)," *Indonesian Journal Of Civil Society*, vol. 2, no. 2, pp. 28–36, 2020, doi: 10.35970/madani.v1i1.233.
- [8] B. Setiyono *et al.*, "Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 2, pp. 385–392, 2023, doi: 10.25126/jtiik.2023106809.
- [9] S. Fifin Alamsyah, "Implementasi Deep Learning Untuk Klasifikasi Tanaman Toga Berdasarkan Ciri Daun Berbasis Android," *Ubiquitous: Computers and its Applications Journal*, vol. 2, no. 2, pp. 113–122, 2020, doi: 10.51804/ucaiaj.v2i2.113-122.
- [10] D. Intan Permatasari, "Implementasi Metode Convolutional Neural Network (CNN) Untuk Klasifikasi Tanaman Herbal Berdasarkan Citra Daun," *Kohesi: Jurnal Sains dan Teknologi*, vol. 3, no. 9, pp. 1–10, 2024, doi: 10.3785/kohesi.v3i9.3953.
- [11] R. Pujiati and N. Rochmawati, "Identifikasi Citra Daun Tanaman Herbal Menggunakan Metode Convolutional Neural Network (CNN)," *Journal of Informatics and Computer Science*, vol. 03, no. 03, pp. 351–357, 2022, doi: 10.26740/jinacs.v3n03.p351-357.

- [12] D. Irfansyah *et al.*, “Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi,” *Jurnal Informatika: Jurnal Pengembang IT*, vol. 6, no. 2, pp. 87–92, 2021, doi: 10.30591/jpit.v6i2.2802.
- [13] Bella Dwi Mardiana, Wahyu Budi Utomo, Ulfah Nur Oktaviana, Galih Wasis Wicaksono, and Agus Eko Minarno, “Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 1, pp. 20–26, Feb. 2023, doi: 10.29207/resti.v7i1.4550.
- [14] R. Akter and M. I. Hosen, “CNN-based Leaf Image Classification for Bangladeshi Medicinal Plant Recognition,” in *ETCCE 2020 - International Conference on Emerging Technology in Computing, Communication and Electronics*, Institute of Electrical and Electronics Engineers Inc., Dec. 2020. doi: 10.1109/ETCCE51779.2020.9350900.
- [15] J. Wijaya, S. Putra Sutra, P. Wahyu Kosasih, P. Sirait, and J. SIFO Mikroskil, “Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun,” *Jurnal SIFO Mikroskil*, vol. 21, no. 1, pp. 1–5, 2020, doi: 10.55601/jsm.v21i1.
- [16] H. Fonda, Y. Irawan, A. Febriani, and H. T. Pekanbaru, “Klasifikasi Batik Riau Dengan Menggunakan Convolutional Neural Networks (CNN),” 2020. doi: 10.33060/JIK/2020/Vol9.Iss1.144.