

IDENTIFIKASI DAUN HERBAL UNTUK TANAMAN OBAT MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)

Husnul Kamilia Zulfiani, Sucipto, Asrul Abdullah
Teknik Informatika, Universitas Muhammadiyah Pontianak
Jl. A Yani No.111, Pontianak, Indonesia 78124
211220013@unmuhpnk.ac.id

ABSTRAK

Tanaman herbal memiliki potensi besar sebagai pengobatan tradisional, tetapi proses identifikasi jenis daun masih dilakukan secara manual sehingga rawan kesalahan dan membutuhkan waktu lama. Penelitian ini bertujuan mengembangkan sistem identifikasi daun herbal otomatis menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *InceptionV3* berbasis *transfer learning*. Dataset terdiri dari 10 kelas daun herbal dengan total 1.000 citra yang melalui proses *preprocessing* (*resize*, normalisasi, augmentasi) dan pembagian data 59% latih, 29% validasi, dan 12% uji. Pelatihan dilakukan selama 30 *epoch* dan implementasi sistem berbasis *Streamlit*. Hasil pelatihan menunjukkan akurasi latih 93,99%, validasi 74,83%, dan uji 51,67%, dengan nilai rata-rata *macro precision* 0,50, *recall* 0,52, dan *F1-score* 0,49. Perbedaan akurasi tersebut mengindikasikan terjadinya *overfitting* akibat keterbatasan data dan kemiripan morfologis antar kelas daun. Temuan ini menegaskan perlunya optimasi model, penambahan variasi data, serta pengembangan arsitektur yang lebih sesuai untuk meningkatkan kemampuan generalisasi.

Kata kunci : *Convolutional Neural Network, InceptionV3, Daun Herbal, Deep Learning, Streamlit*

1. PENDAHULUAN

Para ahli botani umumnya mengidentifikasi tanaman obat melalui ciri morfologi seperti warna, tekstur, dan bentuk daun. Menurut data Kementerian Kesehatan Indonesia, terdapat 19.871 tanaman obat yang digunakan sebagai obat tradisional, namun hanya 16.218 yang berhasil diidentifikasi. Dari jumlah tersebut, sekitar 9.600 spesies diketahui memiliki khasiat obat dan hanya 200 spesies yang dimanfaatkan sebagai bahan baku pengobatan tradisional. Permasalahan yang muncul, terutama di daerah perkotaan, adalah masih minimnya pengetahuan masyarakat mengenai daun herbal yang dapat digunakan sebagai obat alami [1].

Meskipun daun herbal memiliki ciri visual yang relatif mudah dibedakan namun, proses identifikasi manual memiliki kelemahan dari segi kecepatan, akurasi, dan konsistensi. Untuk mengatasi tantangan ini, diperlukan pendekatan otomatis yang mampu mengenali pola visual daun secara andal. Salah satu pendekatan yang banyak digunakan dalam klasifikasi citra adalah *Convolutional Neural Network (CNN)*, karena kemampuannya mengekstraksi fitur secara otomatis dan mendalam.

Penelitian sebelumnya oleh Noor Aini Mohd Roslan et al. mengembangkan sistem pengenalan tanaman herbal di Malaysia dengan memanfaatkan CNN. Hasil pengujian pada data nyata menunjukkan akurasi rata-rata sekitar 75%, yang menandakan adanya potensi pengembangan lebih lanjut dalam penelitian serupa, baik melalui optimasi arsitektur maupun peningkatan kualitas dataset [2].

Seiring kemajuan teknologi *digital image processing*, metode CNN menjadi salah satu algoritma yang unggul dalam tugas klasifikasi citra. CNN memiliki kemampuan untuk mengekstraksi fitur

penting secara otomatis tanpa campur tangan manual, serta mampu mengenali pola visual dari citra yang diproses dalam bentuk matriks [3]. Keunggulan ini menjadikan CNN sangat efisien dan ideal untuk dikembangkan dalam sistem identifikasi daun herbal secara otomatis [4].

Dalam penelitian ini digunakan arsitektur *InceptionV3*, yang dikenal efisien dalam menangkap fitur multi-skala dan memiliki jumlah parameter lebih ringan dibandingkan model besar lainnya seperti VGG16 atau ResNet50. *InceptionV3* juga cocok untuk skenario *transfer learning* pada dataset terbatas, sehingga dapat memberikan hasil klasifikasi yang baik tanpa melatih seluruh model dari awal [2]. Pemilihan arsitektur ini diharapkan dapat membantu mengatasi keterbatasan dataset dan meningkatkan kinerja model pada proses identifikasi daun herbal.

Berdasarkan latar belakang tersebut, penelitian ini berfokus pada “Identifikasi Daun Herbal untuk Tanaman Obat Menggunakan Metode CNN”. Tujuan utamanya adalah mengimplementasikan dan menguji arsitektur *InceptionV3* untuk mengidentifikasi citra daun herbal secara otomatis. Tantangan utama bukan hanya mengotomatisasi proses identifikasi, tetapi juga memastikan model mampu melakukan generalisasi dengan baik pada variasi citra daun di dunia nyata.

2. TINJAUAN PUSTAKA

Penelitian Meilan Ezperanza Florentiana Letik dan Franki Yusuf Bisilisin berjudul “*Klasifikasi Tanaman Herbal Berdasarkan Tekstur Daun Menggunakan Backpropagation Berbasis Citra*”. Hasil pengujian menunjukkan bahwa metode *Backpropagation Neural Network* dengan ekstraksi fitur GLCM mampu mencapai akurasi tertinggi sebesar 85% dan rata-rata 80,5% [5].

Penelitian selanjutnya oleh Raihan Maulana dkk. yang berjudul “*Identifikasi Jenis Rempah-Rempah Indonesia dengan CNN Menggunakan Arsitektur VGG16*” berhasil mengklasifikasikan 31 jenis rempah dengan akurasi tertinggi sebesar 86,66%. Model CNN berbasis VGG16 terbukti efektif dalam menangani data citra rempah dengan hasil validasi mencapai 82,72% [6].

Musyaffa dkk dalam penelitian yang berjudul “*Pengakuan Tanaman Obat Indonesia Menggunakan Transfer learning dan Deep Learning*” menunjukkan bahwa CNN dengan *transfer learning* jauh lebih baik dibandingkan model dari awal (*scratch*). Model *transfer learning* mampu mencapai akurasi hingga 92,5%, sedangkan model CNN *scratch* hanya 53,9% [7].

Penelitian Hidayat dkk, berjudul “*Identifikasi Kualitas Benih Jahe Menggunakan CNN*” menggunakan 1.187 citra benih jahe dan menghasilkan akurasi sebesar 88%. Hal ini menunjukkan bahwa CNN dapat digunakan untuk identifikasi kualitas benih secara non-destruktif dan otomatis [8].

Penelitian terakhir oleh Noor Aini Mohd Roslan dkk, yang berjudul “*Pengenalan Tanaman Otomatis Menggunakan CNN pada Tanaman Obat Malaysia*” menunjukkan bahwa akurasi rata-rata sebesar 75% diperoleh pada data nyata, namun meningkat hingga 88% setelah dilakukan augmentasi data. Hal ini membuktikan bahwa kualitas dataset sangat berpengaruh terhadap performa CNN [2].

Berdasarkan uraian penelitian terdahulu, dapat disimpulkan bahwa meskipun berbagai penelitian sebelumnya telah menunjukkan efektivitas CNN dalam klasifikasi citra tanaman, masih terdapat beberapa tantangan yang belum sepenuhnya teratasi. Sebagian besar penelitian terdahulu berfokus pada pencapaian akurasi tinggi, namun belum banyak yang menganalisis secara mendalam masalah *overfitting* yang muncul ketika dataset relatif terbatas dan antar kelas memiliki kemiripan visual tinggi. Selain itu, pemilihan arsitektur model sering kali tidak disertai dengan evaluasi kritis terhadap keterbatasannya dalam proses generalisasi. Oleh karena itu, penelitian ini tidak hanya mengimplementasikan arsitektur *InceptionV3*, tetapi juga menganalisis performa model secara lebih mendalam untuk mengidentifikasi faktor penyebab penurunan akurasi pengujian dan memberikan dasar untuk perbaikan di masa mendatang.

2.1. Pengolahan Citra Digital

Pengolahan Citra Digital (*Digital Image Processing*) merupakan cabang ilmu komputer yang berfokus pada pemrosesan gambar digital menggunakan perangkat lunak. Gambar atau citra yang dimaksud dapat berupa foto (gambar diam) maupun video (gambar bergerak). Tujuan dari pengolahan citra adalah untuk meningkatkan kualitas visual citra atau mengekstraksi informasi penting dari

citra tersebut agar dapat dikenali oleh manusia maupun sistem komputer secara otomatis [9].

Dalam konteks pengenalan objek seperti identifikasi daun herbal pengolahan citra berperan penting untuk menyiapkan data sebelum dianalisis oleh algoritma klasifikasi berbasis pembelajaran mesin, seperti *Convolutional Neural Network (CNN)* [10]. Tahapan umum meliputi akuisisi citra, *pre-processing* (*resize*, normalisasi, augmentasi), dan klasifikasi sehingga sistem dapat mengenali pola visual secara lebih akurat.

2.2. Identifikasi


Identifikasi merupakan komponen yang berfungsi untuk melakukan pengenalan atau identifikasi objek pada citra digital [5]. Komponen dalam proses identifikasi biasanya mencakup pembacaan objek (*object detection/segmentation*), pengelompokan (*clustering*), pencocokan dengan basis data (*database lookup*), dan penentuan label akhir (*recognition*) [10].

Identifikasi tumbuhan merupakan proses untuk menentukan identitas atau jati diri suatu tumbuhan. Melalui proses identifikasi, dapat diketahui identitas tumbuhan yang berupa nama atau posisinya dalam klasifikasi tumbuhan [11].

2.3. Convolutional Neural Network

Convolutional Neural Network merupakan algoritma *deep learning* yang dikembangkan dari MLP (*Multi Layer Perceptron*) dan bisa memproses data grid seperti suara dan gambar. CNN umum digunakan untuk tugas klasifikasi, deteksi, dan segmentasi citra karena kemampuannya mengekstraksi fitur visual secara bertingkat tanpa memerlukan ekstraksi fitur manual [12].

Komponen utama CNN meliputi lapisan konvolusi (*convolutional layer*) untuk ekstraksi fitur lokal, lapisan *pooling* untuk mereduksi dimensi dan meningkatkan invarian translasi, lapisan aktivasi (mis. ReLU) untuk memasukkan non-linearitas, serta lapisan *fully connected* untuk klasifikasi akhir. Selain itu, teknik seperti *dropout* dan *batch normalization* sering digunakan untuk mencegah *overfitting* dan menstabilkan pelatihan. CNN juga sering dikombinasikan dengan pendekatan *transfer learning* ketika dataset relatif kecil agar memperoleh performa lebih baik. Berikut merupakan gambar struktur *Convolutional Neural Network*.



Gambar 1. *Convolutional Neural Network*

2.4. Daun Herbal


Daun merupakan organ tanaman yang umumnya berwarna hijau dan berfungsi sebagai tempat utama terjadinya proses fotosintesis melalui penyerapan energi cahaya matahari. Selain berperan penting bagi pertumbuhan tanaman, daun juga bermanfaat bagi manusia, khususnya dalam menjaga kesehatan tubuh. Hal ini disebabkan karena daun mengandung berbagai senyawa bioaktif seperti antioksidan, vitamin, mineral, serta zat gizi lain yang memiliki khasiat. Oleh karena itu, daun banyak dimanfaatkan sebagai bahan utama dalam pengobatan herbal maupun tradisional [13].

2.5. Tanaman Obat

Tanaman obat adalah tumbuhan yang dimanfaatkan untuk keperluan pengobatan tradisional atau modern tanpa melalui proses kimia sintetis. Salah satu bagian tanaman obat (herbal) yang bisa dipakai sebagai bahan baku pembuatan obat tradisional yaitu daunnya [14]. Tanaman obat berperan penting dalam pengobatan tradisional dan modern, dengan identifikasi yang akurat menjadi kunci pemanfaatannya. Penelitian ini berfokus pada identifikasi daun herbal untuk tanaman obat memakai metode *Convolutional Neural Network* untuk meningkatkan akurasi dan efisiensi dalam deteksi otomatis spesies tanaman obat.

2.6. InceptionV3

InceptionV3 adalah salah satu arsitektur CNN generasi lanjut yang dikembangkan oleh Google. Arsitektur ini menggunakan konsep *inception modules* yang menggabungkan konvolusi dengan ukuran kernel berbeda dalam satu blok untuk menangkap fitur pada berbagai skala, serta menerapkan teknik faktorisasi konvolusi untuk mengurangi jumlah parameter dan komputasi tanpa kehilangan performa. Karena efisiensi parameter dan kemampuan menangkap fitur multi-skala, *InceptionV3* sering dipilih sebagai model pretrained untuk *transfer learning* pada tugas klasifikasi citra, termasuk identifikasi tanaman [15]. Pada Gambar 2 memperlihatkan arsitektur *InceptionV3* yang digunakan pada penelitian ini.



Gambar 2. Arsitektur *InceptionV3*

2.7. Confusion Matrix

Confusion Matrix adalah alat evaluasi kinerja model identifikasi yang dipakai untuk mengukur seberapa besar model memperkirakan kelas data dengan benar [16]. *Confusion Matrix* merupakan alat evaluasi kinerja model identifikasi yang mengukur

seberapa besar model memperkirakan kelas data dengan tepat. Berikut Tabel 1 menyajikan contoh *Confusion Matrix* untuk evaluasi prediksi.

Tabel 1. *Confusion Matrix*

Aktual	Prediksi	
	Positif	Negatif
Positif	TP	FN
Negatif	FP	TN

Pada Tabel 1, ada empat istilah yang mewakili hasil proses identifikasi dalam *Confusion Matrix*, antara lain:


- True Positive* (TP), data positif yang diperkirakan dengan benar.
- True Negative* (TN), data negatif yang diperkirakan dengan benar.
- False Positive* (FP), error Tipe 1, data negatif tetapi diperkirakan sebagai data positif.
- False Negative* (FN), error Tipe 2, data positif tetapi diperkirakan sebagai data negatif.

3. METODE PENELITIAN

Penelitian ini bertujuan untuk mengidentifikasi daun herbal menggunakan metode *Convolutional Neural Network* dengan arsitektur *InceptionV3* berbasis *transfer learning*. Penelitian dilaksanakan pada platform *Google Colaboratory* dengan bahasa pemrograman *Python* dan library *TensorFlow* serta *Keras*.

3.1. Pengumpulan Data

Data penelitian terdiri dari 10 kelas daun herbal, yaitu daun jambu biji, kelor, kunyit, katuk, sirsak, kemangi, jeruk, belimbing wuluh, kari, dan salam. Sumber data diperoleh dari *Kaggle*, *Mendeley Data*, serta hasil pengambilan citra secara langsung. Gambar 3 menampilkan dataset daun herbal yang digunakan.



Gambar 3. Dataset

Dataset dibagi menjadi 59% data latih, 29% data validasi, dan 12% data uji. Rasio ini dipilih secara sengaja untuk memperbesar porsi data validasi, sehingga proses pemantauan *overfitting* dan evaluasi performa generalisasi selama pelatihan dapat dilakukan secara lebih akurat. Dengan proporsi validasi yang lebih besar, peneliti dapat menganalisis tren akurasi dan *loss* model secara lebih stabil pada setiap *epoch*, sehingga memudahkan dalam menentukan titik optimal pelatihan serta mendeteksi indikasi *overfitting* secara lebih awal.

Tabel 2. Jumlah dataset

Jenis Data	Jumlah Gambar	Jumlah Per Gambar	Jumlah Kelas
Data Latih	590	59	10 kelas
Data Validasi	290	29	10 kelas
Data Uji	190	12	10 kelas

3.2. Preprocessing

Citra yang dikumpulkan diubah ukurannya menjadi 299×299 piksel, dinormalisasi ke rentang $[0,1]$, dan dilakukan augmentasi berupa rotasi, *flipping*, *zooming*, dan *shifting*. Tahap *preprocessing* bertujuan untuk menyeragamkan data, memperkaya variasi citra, serta mengurangi risiko *overfitting*. Gambar 4 memperlihatkan proses *preprocessing* berupa *resize* citra ke ukuran 299×299 piksel.



Gambar 4. Resize gambar

3.3. Perancangan Model

Model penelitian menggunakan arsitektur *InceptionV3* pretrained *ImageNet*. Lapisan *fully connected* terakhir diganti dengan *dense layer* berisi 10 *neuron (softmax)* sesuai jumlah kelas daun herbal. Pada tahap awal, lapisan dasar dibekukan, kemudian dilakukan *fine-tuning* untuk menyesuaikan bobot dengan dataset herbal.

3.4. Pelatihan Model

Proses pelatihan dijalankan dengan parameter 30 *epoch*, *batch size* 32, optimizer Adam, dan *learning rate* 0.0001. Fungsi *loss* yang digunakan adalah *categorical crossentropy*.

3.5. Pengujian Model

Model dievaluasi menggunakan data uji dengan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil pengujian ditampilkan dalam bentuk *Confusion Matrix* serta grafik akurasi dan *loss* untuk memantau performa pelatihan.

3.6. Implementasi

Tahap implementasi dilakukan dengan mengintegrasikan model CNN berbasis *InceptionV3* yang telah dilatih ke dalam aplikasi berbasis web menggunakan *Streamlit*. Aplikasi ini dirancang agar pengguna dapat mengunggah citra daun herbal dan memperoleh hasil klasifikasi secara langsung, serta menampilkan performa model berupa *Confusion Matrix* dan *classification report*. Implementasi ini bertujuan untuk memudahkan pemanfaatan model

dalam identifikasi daun herbal secara praktis dan *real-time*.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pelatihan

Proses pelatihan model dilakukan selama 30 *epoch* dengan hasil seperti ditunjukkan pada Tabel 3. Dari tabel terlihat bahwa akurasi pelatihan meningkat secara bertahap hingga mencapai 93,99% pada *epoch* ke-30, sedangkan akurasi validasi hanya mencapai 74,83%. Perbedaan antara akurasi latih dan validasi ini menunjukkan adanya indikasi *overfitting* pada model.

Tabel 3. Hasil pelatihan


Epoch	Accuracy	Loss	Val_Accuracy	Val_Loss
1	0.0828	2.6423	0.1276	2.2737
2	0.1603	2.3242	0.2345	2.1355
3	0.2506	2.1327	0.4103	2.0095
4	0.3036	1.9680	0.5448	1.8943
5	0.3835	1.8219	0.6103	1.7887
6	0.4670	1.6512	0.6483	1.6956
7	0.4880	1.6021	0.6724	1.6077
8	0.6122	1.3906	0.6931	1.5317
9	0.6533	1.3182	0.7000	1.4612
10	0.6767	1.2424	0.7069	1.4009
11	0.7342	1.1390	0.7103	1.3416
12	0.7558	1.0686	0.7069	1.2970
13	0.7951	1.0112	0.7241	1.2460
14	0.8274	0.9562	0.7207	1.2030
15	0.8480	0.8352	0.7310	1.1720
16	0.7757	0.9325	0.7207	1.1389
17	0.8456	0.8171	0.7207	1.1098
18	0.8651	0.7622	0.7241	1.0812
19	0.8931	0.6980	0.7310	1.0601
20	0.8908	0.6519	0.7310	1.0400
21	0.9243	0.5851	0.7276	1.0202
22	0.9156	0.6140	0.7241	1.0008
23	0.9127	0.5691	0.7310	0.9819
24	0.8950	0.5447	0.7345	0.9653
25	0.9150	0.5289	0.7241	0.9546
26	0.9005	0.5217	0.7241	0.9391
27	0.9206	0.5005	0.7207	0.9240
28	0.9497	0.4378	0.7414	0.9084
29	0.9306	0.4830	0.7483	0.8972
30	0.9399	0.4521	0.7483	0.8840

Akurasi validasi relatif stabil pada kisaran 72–74% dengan nilai *loss* yang tidak stabil namun cenderung menurun dari 2,2737 menjadi 0,8840. Kondisi ini mengindikasikan adanya kesenjangan performa antara data latih dan validasi, sehingga model berpotensi mengalami *overfitting*.

4.2. Visualisasi Akurasi dan Loss

Grafik akurasi dan *loss* ditunjukkan pada Gambar 5. Akurasi data latih meningkat tajam seiring bertambahnya *epoch*, sedangkan akurasi validasi cenderung stagnan di sekitar 73–75%. Grafik *loss* memperlihatkan penurunan signifikan pada data latih, sementara *loss* validasi cenderung tidak stabil. Pola ini menegaskan bahwa model belajar dengan baik pada

data latih, namun generalisasi terhadap data validasi belum optimal.



Gambar 5. Visualisasi akurasi dan loss

Perbedaan tren akurasi antara data latih dan validasi menunjukkan terjadinya *overfitting* pada model. Akurasi data latih meningkat tajam hingga 93,99%, sedangkan akurasi validasi hanya stabil di kisaran 73–75%. Perbedaan ini mengindikasikan bahwa model terlalu menyesuaikan diri pada data pelatihan dan tidak mampu melakukan generalisasi dengan baik.

Kondisi ini juga terkonfirmasi oleh akurasi data uji sebesar 51,67%, yang jauh lebih rendah dibandingkan akurasi pelatihan. Faktor penyebabnya antara lain jumlah dataset yang terbatas, kurangnya variasi citra, serta kompleksitas arsitektur *InceptionV3*. Kesalahan klasifikasi terutama terjadi pada kelas katuk dan sirsak, yang kemungkinan besar disebabkan kemiripan bentuk dan warna daun dengan kelas lain.

4.3. Hasil Pengujian

Pengujian menggunakan 12% data uji menghasilkan akurasi sebesar 51,67% dengan nilai *loss* 1,5018. Untuk melihat kinerja per kelas, dilakukan evaluasi melalui *classification report* pada Tabel 4.

Tabel 4. Hasil *Classification Report*

Kelas	Precision	Recall	F1-score
Belimbing Wuluh	0.31	0.83	0.45
Daun Jeruk	0.47	0.58	0.52
Daun Kari	0.42	0.67	0.52
Daun Katuk	0.00	0.00	0.00
Daun Kelor	0.83	0.83	0.83
Daun Kemangi	0.14	0.08	0.11
Daun Kunyit	1.00	0.83	0.91
Daun Sirih	0.80	0.67	0.73
Daun Sirsak	0.00	0.00	0.00
Jambu Biji	1.00	0.67	0.80
Rata-rata			
Macro Average	0,50	0,52	0,49

Hasil ini menunjukkan bahwa kelas daun kunyit dan jambu biji dapat dikenali dengan baik dengan nilai *F1-score* di atas 0,80. Sebaliknya, kelas daun katuk dan daun sirsak tidak terdeteksi sama sekali karena nilai *precision* dan *recall* = 0. Distribusi hasil prediksi model secara rinci ditampilkan pada Tabel 5 dalam bentuk *Confusion Matrix*.

Tabel 5. Hasil *Confusion Matrix*

No	Kelas	TP	FP	FN	TN
1	Belimbing Wuluh	10	16	2	92
2	Daun Jeruk	7	7	5	101
3	Daun Kari	8	4	4	104
4	Daun Katuk	0	1	12	107
5	Daun Kelor	10	0	2	108
6	Daun Kemangi	6	7	6	101
7	Daun Kunyit	10	0	2	108
8	Daun Sirih	8	3	4	105
9	Daun Sirsak	0	0	12	108
10	Jambu Biji	8	2	4	106

Berdasarkan Tabel 5, terlihat bahwa beberapa kelas daun berhasil diklasifikasikan dengan cukup baik, seperti daun kunyit dan daun kelor yang memiliki nilai *true positive* tinggi serta kesalahan prediksi yang minimal. Sebaliknya, daun katuk dan daun sirsak sama sekali tidak terdeteksi dengan benar (*true positive* = 0), sehingga seluruh citra kedua kelas tersebut diprediksi sebagai kelas lain. Selain itu, ditemukan adanya pola kesalahan pada kelas daun jeruk dan daun kemangi yang saling tertukar, kemungkinan karena bentuk dan tekstur keduanya relatif mirip. Temuan ini menunjukkan bahwa keterbatasan jumlah data dan kemiripan fitur visual antar kelas sangat memengaruhi kinerja model dalam melakukan klasifikasi.

Gambar 6 menunjukkan contoh citra daun katuk dan sirsak yang salah diprediksi oleh model. Daun katuk diprediksi sebagai daun jeruk, sedangkan daun sirsak diprediksi sebagai belimbing wuluh. Kesalahan ini terjadi karena kemiripan bentuk daun dan tekstur permukaan yang menyerupai kelas lainnya, serta keterbatasan jumlah data.



Gambar 6. Contoh kesalahan prediksi pada citra daun katuk dan daun sirsak.


4.4. Implementasi Sistem

Model yang dikembangkan diimplementasikan pada aplikasi berbasis web menggunakan *Streamlit*, sebagaimana terlihat pada Gambar 7, di mana pengguna dapat memilih menu navigasi pada sisi kiri layar yang terdiri dari Identifikasi dan Performa Model.




Gambar 7. Tampilan Halaman Utama

Pada menu Identifikasi yang ditunjukkan pada Gambar 8, pengguna dapat mengunggah citra daun herbal dalam format JPG, JPEG, atau PNG. Setelah citra berhasil diunggah, sistem akan menampilkan gambar tersebut beserta hasil prediksi kelas daun herbal yang terdeteksi. Misalnya, citra daun yang diuji berhasil diidentifikasi sebagai Belimbing Wuluh.



Gambar 8. Tampilan Hasil Identifikasi

Sementara itu, menu Performa Model yang ditunjukkan pada Gambar 9 menampilkan hasil evaluasi model berupa *Confusion Matrix* dan *classification report*. Visualisasi ini memberikan gambaran mengenai distribusi prediksi model serta nilai evaluasi pada masing-masing kelas daun herbal.



Gambar 9. Tampilan Performa Model

Dengan adanya implementasi sistem ini, model *InceptionV3* yang telah dikembangkan dapat dimanfaatkan secara praktis, sehingga pengguna tidak perlu melakukan proses pelatihan ulang untuk mengidentifikasi daun herbal.

4.5. Pengujian Aplikasi

Pengujian aplikasi dilakukan untuk memastikan sistem identifikasi daun herbal yang telah diimplementasikan dapat berjalan sesuai dengan fungsinya. Pengujian dilakukan secara fungsional menggunakan metode *black box testing*, dengan fokus pada fitur-fitur utama, yaitu pengunggahan citra daun

herbal, proses klasifikasi, serta penampilan hasil prediksi pada antarmuka pengguna. Pendekatan ini bertujuan untuk mengevaluasi apakah setiap fitur pada aplikasi telah bekerja sesuai dengan rancangan dan dapat digunakan oleh pengguna dengan baik.

Hasil pengujian menunjukkan bahwa aplikasi dapat menerima citra daun dalam format JPG dan PNG, melakukan proses klasifikasi secara *real-time* dengan waktu respon kurang dari dua detik, serta menampilkan hasil identifikasi beserta label nama daun herbal pada antarmuka pengguna. Tampilan proses identifikasi dan visualisasi performa model ditunjukkan pada Gambar 7, Gambar 8, dan Gambar 9.

Secara keseluruhan, seluruh fungsi utama aplikasi, seperti pengunggahan gambar, prediksi kelas daun, dan tampilan hasil klasifikasi, telah berjalan sesuai dengan rancangan. Hal ini membuktikan bahwa sistem siap digunakan secara praktis oleh pengguna akhir untuk membantu proses identifikasi daun herbal.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa metode *Convolutional Neural Network* (CNN) dengan arsitektur *InceptionV3* mampu mengklasifikasikan daun herbal dengan akurasi pelatihan tinggi sebesar 93,99%, namun akurasi pengujian masih rendah sebesar 51,67%, dengan rata-rata *macro precision* 0,50, *recall* 0,52, dan *F1-score* 0,49. Hasil ini mengindikasikan adanya *overfitting* pada model akibat keterbatasan data dan variasi citra. Untuk penelitian selanjutnya, disarankan penambahan jumlah dan variasi dataset, penerapan teknik regularisasi seperti *dropout* atau *early stopping*, serta eksplorasi arsitektur model yang lebih ringan seperti *MobileNetV2*. Pengembangan fitur aplikasi juga dapat meningkatkan efektivitas dan kemudahan penggunaan sistem identifikasi daun herbal.

DAFTAR PUSTAKA

- [1] M. Mahromi, M. I. Maulana, M. Alfiansyah, and A. Ramadhan, "Klasifikasi Penyakit Daun Tanaman Menggunakan Convolutional Neural Network (CNN)," *JRIIN: Jurnal Riset Informatika dan Inovasi*, vol. 2, no. 7, 2024. [Online]. Available: <https://jurnalmahasiswa.com/index.php/jriin>
- [2] N. A. M. Roslan, N. M. Diah, Z. Ibrahim, Y. Munarko, and A. E. Minarno, "Pengenalan tanaman otomatis menggunakan jaringan saraf konvolusional pada tanaman obat Malaysia: nilai augmentasi data," *International Journal of Advances in Intelligent Informatics*, vol. 9, no. 1, pp. 136–147, Mar. 2023, doi: 10.26555/ijain.v9i1.1076.
- [3] S. J. Pipin, L. Judijanto, and F. Reba, "Algoritma Pembelajaran Mesin (Dasar, Teknik, dan Aplikasi)," 2024. [Online]. Available: <https://www.researchgate.net/publication/379479664>

- [4] K. Anam and A. Saleh, "Autentikasi Daun Herbal Menggunakan Convolutional Neural Network dan Raspberry Pi," 2020.
- [5] M. E. F. Letik and F. Y. Bisilisin, "Tanaman Herbal Berdasarkan Tekstur Daun Menggunakan Klasifikasi," 2024.
- [6] R. Maulana, R. D. Z. Putri, T. A. Amelia, H. Syahputra, F. Ramadhani, and J. W. Iskandar, "Identifikasi Jenis Rempah-Rempah Indonesia Dengan Convolutional Neural Network (CNN) Menggunakan Arsitektur VGG16," 2024.
- [7] M. S. I. Musyaffa, N. Yudistira, M. A. Rahman, and J. Batoro, "IndoHerb: Pengakuan Tanaman Obat Indonesia menggunakan Transfer learning dan Deep Learning," Jun. 2024. [Online]. Available: <http://arxiv.org/abs/2308.01604>
- [8] H. Hidayat, F. Riana, and G. F. Laxmi, "Identifikasi Kualitas Benih Jahe Menggunakan Convolutional Neural Network (CNN)," Infotech Journal, vol. 9, no. 1, pp. 287–298, Jun. 2023, doi: 10.31949/infotech.v9i1.5458.
- [9] S. R. Fakultas, T. Informasi, U. Islam, K. Muhammad, and A. Al Banjari, "Pengolahan Citra Digital Dan Histogram Dengan Phyton Dan Text Editor Phycharm," 2020.
- [10] J. Jumadi, Y. Yupianti, and D. Sartika, "Pengolahan Citra Digital Untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering," JST (Jurnal Sains dan Teknologi), vol. 10, no. 2, pp. 148–156, Nov. 2021, doi: 10.23887/jst-undiksha.v10i2.33636.
- [11] S. Widya Ulfa et al., "Identifikasi Ciri Morfologis Tumbuhan Tingkat Tinggi pada Ordo Berbeda Di Kampus II UIN Sumatera Utara," 2023.
- [12] M. H. Ahmad, M. Hana, T. Ghazi Pratama, and H. Aulida, "Klasifikasi Empat Jenis Daun Herbal Menggunakan Metode Convolutional Neural Network," 2023.
- [13] R. J. Rumandan, R. Nuraini, N. Sadikin, and Y. Rahmanto, "Klasifikasi Citra Jenis Daun Berkhasiat Obat Menggunakan Algoritma Jaringan Syaraf Tiruan Extreme Learning Machine," Journal of Computer System and Informatics (JoSYC), vol. 4, no. 1, pp. 145–154, Dec. 2022, doi: 10.47065/josyc.v4i1.2586.
- [14] Meiriyama and Sudiadi, "Penerapan Algoritma Random Forest Untuk Klasifikasi Jenis Daun Herbal," 2022.
- [15] N. Huda et al., "Analisis Performa InceptionV3 Convolutional Network Pada Klasifikasi Varietas Daun Grapevine," 2023.
- [16] D. Iswantoro and D. Handayani, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)," Jurnal Ilmiah Universitas Batanghari Jambi, vol. 22, no. 2, p. 900, Jul. 2022, doi: 10.33087/jiubj.v22i2.2065