

# SENASTIKA Universitas Malikussaleh

---

## SISTEM PENGELOMPOKAN PADA DAUN BERDASARKAN SPESIES DENGAN SEGMENTASI DAN CONVOLUTIONAL NEURAL NETWORK (CNN)

Munirwan<sup>\*1</sup>, Fathul Hadi<sup>2</sup>, Muhammad Hafizal<sup>3</sup>, Agus Setiawan<sup>4</sup>, Muhammad Zakky<sup>5</sup>, Munirul Ula<sup>6</sup>

<sup>1,2,3,4,5,6</sup> Teknik Informatika, Universitas Malikussaleh, Lhokseumawe, Aceh

Email: <sup>1</sup> [munirwan.210170287@mhs.unimal.ac.id](mailto:munirwan.210170287@mhs.unimal.ac.id), <sup>2</sup> [fathul.210170288@mhs.unimal.ac.id](mailto:fathul.210170288@mhs.unimal.ac.id),  
<sup>3</sup> [muhhammad.210170286@mhs.unimal.ac.id](mailto:muhhammad.210170286@mhs.unimal.ac.id), <sup>4</sup> [agus.210170283@mhs.unimal.ac.id](mailto:agus.210170283@mhs.unimal.ac.id), <sup>5</sup> [muhhammad.210170285@mhs.unimal.ac.id](mailto:muhhammad.210170285@mhs.unimal.ac.id), <sup>6</sup> [munirulula@unimal.ac.id](mailto:munirulula@unimal.ac.id)

### Abstrak

Identifikasi spesies tumbuhan berdasarkan morfologi daun secara manual membutuhkan keahlian khusus, ketelitian, serta waktu yang tidak sedikit, terutama karena variasi bentuk dan ukuran daun antarspesies sangat beragam. Tantangan ini seringkali memperlambat proses identifikasi tumbuhan secara konvensional. Dalam penelitian ini, digunakan pendekatan otomatis yang memanfaatkan Convolutional Neural Network (CNN) dan teknik segmentasi citra untuk mengelompokkan spesies daun secara akurat. Proses segmentasi citra dilakukan menggunakan metode thresholding dan morfologi, yang bertujuan untuk memisahkan objek daun dari latar belakang, sehingga fitur-fitur penting dari morfologi daun dapat diidentifikasi dengan lebih baik. Setelah objek daun tersegmentasi dengan jelas, model CNN digunakan untuk melakukan klasifikasi. CNN bekerja dengan menerapkan beberapa lapisan konvolusi yang bertugas mengekstraksi fitur lokal dari daun, serta menggunakan lapisan pooling untuk mereduksi dimensi data tanpa mengurangi informasi yang relevan. Dataset yang beragam dari berbagai gambar daun digunakan untuk melatih model CNN agar dapat mengenali pola morfologi daun dari berbagai spesies tumbuhan. Hasil penelitian menunjukkan bahwa metode ini mampu mencapai tingkat akurasi yang tinggi dalam mengklasifikasikan spesies daun. Hal ini mengindikasikan bahwa kombinasi antara segmentasi citra dan CNN merupakan pendekatan yang efektif dan efisien untuk mempercepat serta meningkatkan akurasi proses identifikasi spesies tumbuhan. Pendekatan ini memberikan solusi yang andal dalam bidang botani, tanpa memerlukan intervensi manual yang rumit.

**Kata Kunci:** *Convolutional Neural Network (CNN), Deteksi, Morfologi Daun, Segmentasi Citra, Spesies.*

### Abstract

Identifying plant species based on leaf morphology manually requires specialized expertise, precision, and considerable time, especially due to the variation in shape and size of leaves across different species. This challenge often slows down the conventional process of plant identification. In this research, an automated approach is utilized by leveraging Convolutional Neural Networks (CNN) and image segmentation techniques to accurately classify leaf species. The image segmentation process is carried out using thresholding and morphology methods, which aim to separate the leaf object from the background, thereby enabling better identification of key features of leaf morphology. Once the leaf object is clearly segmented, a CNN model is employed for classification. The CNN works by applying several convolutional layers to extract local features from the leaf and uses pooling layers to reduce the data dimensions without losing information. A diverse dataset of leaf images is used to train the CNN model so that it can recognize the morphological patterns of leaves from various plant species. The research findings demonstrate that this method achieves a high accuracy level in classifying leaf species. This indicates that the combination of image segmentation techniques and CNN is an effective and efficient approach to speeding up and enhancing the accuracy of plant species identification. This approach offers a reliable solution in the field of botany without requiring complex manual intervention.

**Keywords:** *Convolutional Neural Network (CNN), Detection, Leaf Morphology, Image Segmentation, Species.*

---

## 1. PENDAHULUAN

Identifikasi dan pengelompokkan spesies tumbuhan berdasarkan morfologi daun memiliki peran penting dalam berbagai bidang, seperti botani, pertanian, hingga konservasi lingkungan. Namun, proses ini sering kali dilakukan secara manual, yang membutuhkan keahlian khusus dan waktu yang tidak sedikit. Dengan kemajuan

teknologi kecerdasan buatan (Artificial Intelligence/AI) dan pengolahan citra digital, pendekatan otomatis dalam pengenalan dan pengelompokan spesies daun dapat menjadi solusi yang efisien dan akurat [1].

Salah satu teknik yang telah terbukti unggul dalam klasifikasi dan pengenalan citra adalah *Convolutional Neural Network* (CNN), yang dikenal memiliki kemampuan luar biasa dalam mengekstraksi fitur dari gambar. CNN mampu mengenali pola-pola yang kompleks dalam gambar melalui lapisan-lapisan konvolusi yang bertugas untuk mendeteksi fitur lokal, seperti tepi, tekstur, hingga bentuk keseluruhan objek. Dalam konteks klasifikasi spesies daun, CNN dapat digunakan untuk menganalisis berbagai karakteristik daun seperti bentuk, ukuran, dan tekstur dengan akurasi yang tinggi [2].

Selain CNN, proses segmentasi citra juga berperan penting dalam meningkatkan kinerja sistem klasifikasi. Segmentasi citra adalah proses memisahkan objek utama, dalam hal ini daun, dari latar belakang gambar. Dengan segmentasi yang baik, model CNN dapat lebih fokus pada fitur-fitur penting dari daun tanpa terganggu oleh informasi yang tidak relevan dari latar belakang. Kombinasi antara segmentasi citra yang efektif dan penggunaan CNN diharapkan dapat meningkatkan akurasi pengelompokan spesies daun secara signifikan [3].

Penelitian ini bertujuan untuk mengembangkan sebuah sistem pengelompokan spesies daun yang menggabungkan teknik segmentasi citra dan CNN [4]. Sistem ini diharapkan mampu memberikan solusi yang cepat, akurat, dan efisien dalam mengklasifikasikan daun berdasarkan spesiesnya. Melalui pendekatan ini, diharapkan dapat membantu berbagai pihak dalam melakukan identifikasi dan pelestarian spesies tumbuhan secara lebih efektif [5].

## 2. TINJAUAN PUSTAKA

### 2.1. Convolutional Neural Network (CNN) dalam Pengolahan Citra

Convolutional Neural Network (CNN) merupakan metode deep learning yang dirancang untuk menangani data dengan struktur grid seperti gambar. CNN menggunakan lapisan konvolusi untuk mengekstraksi fitur dari gambar, yang memungkinkan deteksi pola spasial seperti tepi, sudut, dan tekstur. Pada CNN, input gambar dikonvolusi dengan filter/kernel untuk menghasilkan fitur map [6].

Rumus dasar dari operasi konvolusi antara input gambar  $I$  dan kernel  $K$  dengan ukuran  $m \times n$  dapat dituliskan Di mana  $S(i,j)$  adalah hasil dari konvolusi,  $I(i,j)$  adalah nilai piksel pada posisi  $(i,j)$ , dan  $K(p,q)$  adalah nilai kernel pada posisi  $(p,q)$ . Operasi ini digunakan untuk mengekstraksi fitur dari gambar daun pada berbagai tahap dalam CNN. CNN juga mencakup lapisan pooling, yang sering digunakan untuk mengurangi dimensi fitur dan mencegah overfitting. Salah satu jenis pooling yang umum adalah max-pooling, yang mengambil nilai maksimum dari setiap wilayah filter [7].

### 2.2. Segmentasi Warna pada Citra Daun

Segmentasi warna bertujuan untuk memisahkan objek (daun) dari latar belakang berdasarkan perbedaan warna. Salah satu teknik yang umum digunakan adalah thresholding. Pada teknik thresholding, setiap piksel pada citra RGB atau HSV dibandingkan dengan nilai ambang batas tertentu, dan piksel yang memenuhi kriteria dimasukkan ke dalam objek daun [8].

### 2.3. TensorFlow dalam Implementasi CNN

TensorFlow menyediakan lingkungan untuk membangun dan melatih model deep learning, termasuk CNN. Salah satu keunggulan TensorFlow adalah kemampuannya dalam mengelola grafis komputasi yang kompleks dan mempercepat pelatihan model menggunakan GPU atau TPU [9].

Rumus backward propagation dalam CNN, yang digunakan TensorFlow untuk memperbarui bobot melalui

### 2.4. Pandas untuk Pengolahan Data

Pandas adalah library Python yang digunakan untuk manipulasi data yang terstruktur. Pada penelitian ini, Pandas digunakan untuk memproses dataset daun yang diperoleh dari Kaggle, mengelola label usia daun, serta mempersiapkan data untuk pelatihan model CNN [10]. Misalnya, untuk mengelola label usia daun, kita bisa menggunakan Pandas untuk membaca dataset dalam format CSV dan menampilkan data yang relevan.

### 2.5. OpenCV untuk Pemrosesan Citra

OpenCV merupakan library yang kuat untuk pemrosesan citra, seperti segmentasi warna, deteksi tepi, dan transformasi gambar. Pada proyek ini, OpenCV digunakan untuk segmentasi daun berbasis warna, serta untuk pra-pemrosesan gambar sebelum masuk ke CNN [11].

## 3. METODOLOGI PENELITIAN

Penelitian ini menggunakan metode pengolahan citra digital berbasis *Convolutional Neural Network* (CNN) untuk mengklasifikasikan spesies daun.

Penelitian ini menggunakan pendekatan kuantitatif dengan eksperimen model jaringan saraf dalam (*deep learning*) untuk melakukan segmentasi gambar daun dan prediksi jenis spesies daun berdasarkan data citra [12].

Data yang digunakan dalam penelitian ini adalah gambar daun dari beberapa spesies yang dikumpulkan melalui berbagai sumber data, baik dari dataset publik maupun dari gambar daun yang diambil secara langsung. Setiap gambar daun memiliki resolusi standar yang telah disesuaikan untuk pelatihan model [13].

Sebelum citra digunakan sebagai masukan ke dalam model CNN, gambar daun harus melalui tahap segmentasi. Segmentasi dilakukan untuk memisahkan objek daun dari latar belakang gambar. Algoritma segmentasi berbasis *thresholding* dan metode morfologi digunakan untuk memperoleh bentuk daun yang optimal sebagaimana masuk ke dalam model.

Model CNN yang digunakan dalam penelitian ini terdiri dari beberapa lapisan (*layers*), seperti yang digambarkan pada Gambar 1. Tabel berikut :

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 150, 150, 32)	2,432
max_pooling2d (MaxPooling2D)	(None, 75, 75, 32)	0
conv2d_1 (Conv2D)	(None, 75, 75, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 37, 37, 64)	0
conv2d_2 (Conv2D)	(None, 37, 37, 96)	55,392
max_pooling2d_2 (MaxPooling2D)	(None, 18, 18, 96)	0
conv2d_3 (Conv2D)	(None, 18, 18, 96)	83,040
max_pooling2d_3 (MaxPooling2D)	(None, 9, 9, 96)	0
flatten (Flatten)	(None, 7776)	0
dense (Dense)	(None, 512)	3,981,824
activation (Activation)	(None, 512)	0
dense_1 (Dense)	(None, 5)	2,565

Total params: 4,143,749 (15.81 MB)

Trainable params: 4,143,749 (15.81 MB)

Non-trainable params: 0 (0.00 B)

Gambar 1. Tabel Sequential


Arsitektur Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini terdiri dari beberapa lapisan *conv2d* dan *pooling*, yang bertugas untuk mengekstraksi fitur-fitur lokal dari gambar daun. Setelah melewati lapisan konvolusi dan *pooling*, fitur-fitur yang telah diambil diteruskan ke lapisan *fully connected* yang bertanggung jawab untuk menghasilkan prediksi akhir. Pada lapisan terakhir, digunakan fungsi aktivasi *softmax*, yang sangat cocok untuk klasifikasi multi-kelas karena dapat memprediksi spesies daun dari beberapa kelas yang berbeda berdasarkan fitur yang dipelajari oleh CNN.

Gambar daun diambil dengan latar belakang bersih dan resolusi yang cukup tinggi untuk mempertahankan detail morfologi daun. Gambar-gambar tersebut kemudian diproses melalui beberapa tahapan pra-pengolahan, termasuk perubahan ukuran gambar menjadi 150x150 piksel agar sesuai dengan input standar untuk jaringan CNN, serta normalisasi piksel untuk meningkatkan efisiensi pelatihan model. Selain itu, segmentasi citra diterapkan untuk memisahkan objek daun dari latar belakang, memastikan bahwa hanya fitur daun yang relevan yang dianalisis oleh CNN. Semua tahapan ini memungkinkan model untuk mengekstraksi pola-pola penting dari morfologi daun, sehingga menghasilkan prediksi spesies dengan akurasi tinggi.

Model CNN dilatih menggunakan dataset yang dibagi menjadi data latih (80%) dan data uji (20%). Data latih digunakan untuk mempelajari pola-pola dalam gambar, sedangkan data uji digunakan untuk mengukur kinerja model dalam melakukan prediksi spesies daun. Pelatihan dilakukan selama beberapa *epoch* hingga model mencapai *convergence* [14].

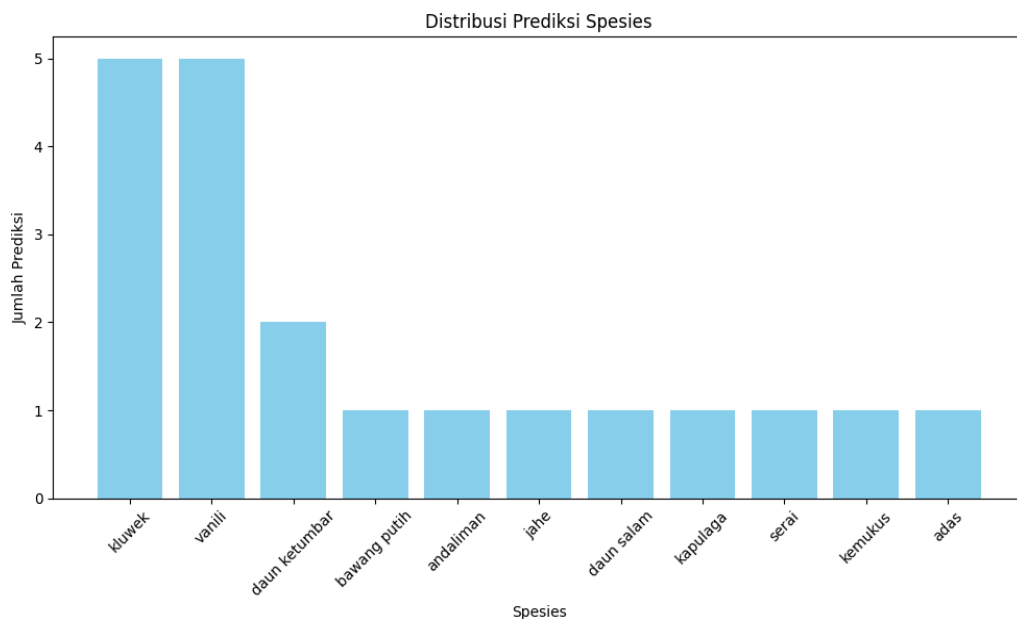
#### 4. HASIL DAN PEMBAHASAN

Evaluasi model dilakukan dengan menggunakan metrik akurasi, presisi, dan *recall* untuk mengukur performa model dalam mengklasifikasikan spesies daun. Selain itu, dilakukan analisis distribusi prediksi spesiesdaun, seperti yang ditunjukkan pada grafik berikut :



Gambar 2. Grafik Akurasi Dan Loss

Validasi model dilakukan menggunakan teknik *k-fold cross-validation* untuk memastikan bahwa model tidak mengalami *overfitting* dan mampu menggeneralisasi dengan baik pada data baru. Selain itu, data uji yang tidak termasuk dalam data pelatihan digunakan untuk mengukur kemampuan model dalam memprediksi spesies daun di luar dataset latih.



Gambar 3. Grafik Prediksi

Melalui pendekatan CNN dan segmentasi citra, penelitian ini berhasil mengembangkan model yang mampu mengklasifikasikan spesies daun secara akurat. Model CNN yang dibangun menunjukkan kinerja yang baik dengan akurasi yang signifikan dalam mengenali berbagai spesies daun.

#### 4.1. Segmentasi Terhadap Daun

Membaca spesies daun melalui segmentasi dapat dilakukan dengan menghubungkan dataset yang ada di google drive. Setelah menghubungkan google colab dengan google drive langkah selanjutnya adalah membuat classes menggunakan code `class names = sorted(os.listdir(data path))` dan `num_classes = len(class names)` lalu akan di tampilkan menggunakan code `print('classes: ', class names)` dari nama folder yang ada di dalam folder dataset yang akan kita jadikan pijakan untuk langkah selanjutnya menuju segmentasi dari spesies daun yang akan di uji.

Dalam kode ini, variabel `data_path` diatur untuk menunjuk ke lokasi folder yang berisi kumpulan data gambar Spice di Google Drive. Class names kemudian dibuat menggunakan `os.listdir(data path)`. Ini mengembalikan daftar nama folder di `data_path`, diurutkan berdasarkan abjad menggunakan `diurutkan()`. Hal ini

memungkinkan setiap folder dianggap sebagai kelas yang berbeda untuk klasifikasi gambar. Variabel ``num\_classes`` dihitung untuk menyimpan jumlah kelas yang ada, dan ``img size`` dihitung untuk menentukan ukuran gambar yang digunakan untuk pemrosesan, yaitu 192 piksel x 192 piksel dalam tiga saluran warna (RGB). Itu akan diatur.

Terakhir, kode tersebut mencetak daftar nama kelas yang diambil dari folder [15].



Gambar 4. Segmentasi Daun

Gambar diatas menunjukkan 2 gambar yang berbeda :

1. Daun Jeruk: Gambar sebelah kiri merupakan hasil pembagian gambar asli dengan nama file "leaf-jeruk\_36.jpg". Daun jeruk biasa digunakan dalam masakan untuk memberikan aroma dan rasa yang unik. Daun Salam: Terlihat di sebelah kanan foto berjudul "Daun Salam".
2. Daun salam merupakan bumbu masakan yang umum digunakan dan memiliki banyak manfaat bagi kesehatan, antara lain memperkuat sistem kekebalan tubuh dan berperan sebagai anti oksidan.

Sesuai caption, ini merupakan hasil proses segmentasi yang memisahkan objek utama (daun jeruk dan daun salam) dari background agar analis atau tampilan lebih fokus.

#### 4.2. Memprediksi Spesies Daun Dengan Convolutional Neural Network (CNN)

```

import os
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator

# Tentukan path dataset
dataset_path = '/content/drive/MyDrive/input/Indonesian Spices Dataset/'

# Membuat generator untuk memuat gambar
datagen = ImageDataGenerator(rescale=1./255, validation_split=0.2)

# Memuat data
train_generator = datagen.flow_from_directory(
    dataset_path,
    target_size=(150, 150),
    batch_size=32,
    class_mode='categorical',
    subset='training'
)

validation_generator = datagen.flow_from_directory(
    dataset_path,
    target_size=(150, 150),
    batch_size=32,
    class_mode='categorical',
    subset='validation'
)

```

Gambar 5. Memvalidasi Data

Kode ini terlebih dahulu mengimpor pustaka yang diperlukan untuk memproses gambar, seperti *TensorFlow* dan *Image Data Generator Keras*. Variabel dataset path disetel untuk menunjuk ke lokasi kumpulan data *Spice* di Google Drive. Selanjutnya, buat objek *Image Data Generator* menggunakan opsi `rescale=1./255`

untuk menormalkan piksel gambar antara 0 dan 1 dan gunakan validation split=0.2 untuk membagi dataset menjadi dua bagian, data pelatihan dan Split menjadi data validasi. Kemudian, untuk mengubah ukuran gambar, kita menggunakan metode flow from directory() dengan parameter target size disetel ke (150, 150) untuk membuat generator untuk pelatihan (train generator) dan data validasi (validasi generator).batch size diatur ke 32 untuk menentukan jumlah gambar yang diproses dalam satu batch, dan class mode diatur ke categorical untuk klasifikasi beberapa kelas. Penggunaan subset=training dan 'subset='validation' di setiap generator menentukan bagian mana dari dataset yang digunakan untuk pelatihan dan validasi.



Gambar 6. Daun Sebelum Proses Train

Gambar yang ditampilkan dengan metode cnn tetapi belum dilakukan pelatihan data nya yaitu epoch data minimal 10 kali literatur dan tujuan pelatihan data adalah untuk membuat sebuah tren accuracy data berupatampilan sebagai berikut :

```

history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // train_generator.batch_size,
    validation_data=validation_generator,
    validation_steps=validation_generator.samples // validation_generator.batch_size,
    epochs=10
    )
    
```

Gambar 7. Melakukan Pelatihan Model Fit

Kode di atas digunakan untuk melatih model menggunakan metode fit pada data yang dihasilkan oleh train generator dan validation generator. Model ini dilatih selama 10 masa di sini epoch berarti satu siklus lengkap untuk seluruh data pelatihan. Parameter "steps per epoch" menentukan jumlah langkah yang dijalankan di setiap epoch. Jumlah total sampel dibagi dengan ukuran batch train generator. Proses validasi dijalankan menggunakan validation generator di akhir setiap epoch. Ini juga mencakup serangkaian langkah yang ditentukan oleh validation steps.

```

# Menyimpan model ke file .h5
model.save('leaf_species_classifier.h5')
    
```

Gambar 8. Menyimpan Model Gambar .h5

Kode diatas adalah untuk menyimpan model yang dilatih ke file bernama 'leaf\_species\_classifier.h5' dalam format HDF5. Hal ini memungkinkan Anda menyimpan arsitektur model, bobot, dan konfigurasi pelatihan (seperti fungsi pengoptimal dan kerugian) sehingga nanti Anda dapat memuat ulang model dan menggunakannya untuk prediksi atau pelatihan lebih lanjut tanpa harus melatih ulang dari awal. Ini berguna ketika Anda ingin menyebarkan model atau membaginya di antara lingkungan atau proyek yang berbeda. Ekstensi ".h5" mengacu pada Hierarchical Data Format (HDF5), yang cocok untuk menyimpan data dalam jumlah besar.

```

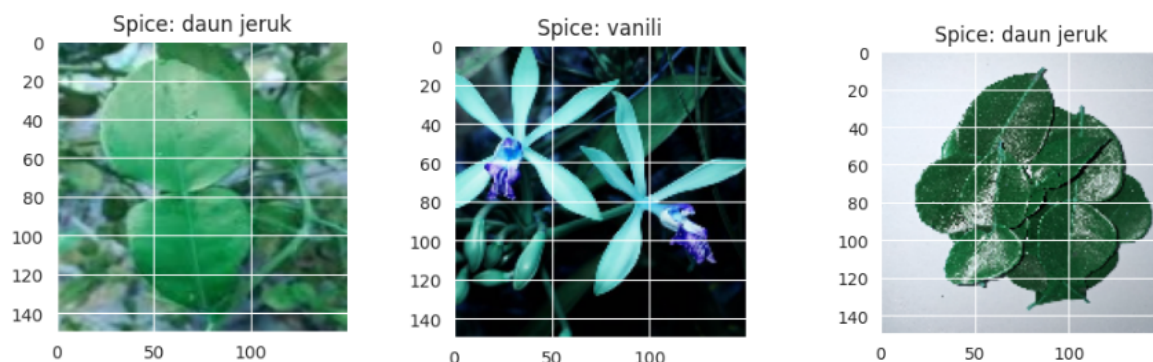
▶ fig,ax=plt.subplots(5,2)
  fig.set_size_inches(15,15)
  for i in range(5):
    for j in range (2):
      l=mn.randint(0,len(Z))
      ax[i,j].imshow(X[l])
      ax[i,j].set_title('Spice: '+Z[l])

plt.tight_layout()

```

Gambar 9. Menampilkan Deteksi Spesies Daun

Kode ini digunakan untuk membuat visualisasi gambar secara berulang menggunakan matplotlib Pertama, plt.subplots 5,2 membuat kisi atau larik subplot berukuran 5 kali 2 dengan total 10 plot. Ukuran keseluruhan gambar diatur dengan fig.set size inches 15,15, sehingga berukuran 15x15 inci. Di dalam dua loop for, sebuah gambar dipilih secara acak dari kumpulan data X menggunakan mn.randint(0, len(Z)), dan gambar acak dari 0 hingga panjang Z adalah Indeks akan menjadi dihasilkan. Kemudian sebuah gambar ditampilkan di setiap plot menggunakan ax[i,j].imshow(X[l]) dan setiap judul subplot adalah nama jenis bumbu yang sesuai dengan nilai Z yang disetel untuk ditampilkan.



Gambar 10. Gambar Hasil Dari Spesies CNN

## 5. DISKUSI

### 5.1. Keakuratan Model CNN dalam Klasifikasi Daun

Efektivitas Convolutional Neural Network (CNN) dalam mengklasifikasikan spesies daun berdasarkan fitur morfologi. Fokus utama adalah bagaimana CNN mampu mengekstraksi pola-pola penting dari gambar daun yang beragam, serta dampak dari penambahan jumlah lapisan konvolusi dan pooling terhadap peningkatan akurasi model. Penggunaan metrik seperti akurasi, presisi, dan recall juga relevan untuk menilai performa model secara komprehensif.

### 5.2. Segmentasi Citra sebagai Pendukung Peningkatan Akurasi

Segmentasi citra memegang peran penting dalam penelitian ini, karena proses segmentasi memisahkan objek daun dari latar belakang, memungkinkan CNN untuk fokus pada fitur morfologi daun. Diskusi dapat mencakup tantangan dalam segmentasi citra, seperti bagaimana variasi pencahayaan atau latar belakang yang tidak seragam dapat mempengaruhi akurasi segmentasi. Selain itu, efektivitas metode *thresholding* dan morfologi dalam mendukung pengklasifikasian yang akurat dapat dibahas lebih lanjut.

### 5.3. Penerapan K-fold Cross-Validation untuk Menghindari Overfitting

Penggunaan teknik k-fold cross-validation sangat penting untuk memastikan bahwa model CNN dapat menggeneralisasi dengan baik pada data baru, bukan hanya "menghafal" dataset pelatihan. Diskusi dapat mencakup bagaimana teknik ini diterapkan dalam penelitian dan dampaknya terhadap performa model, terutama untuk menghindari overfitting.

#### 5.4. Pengaruh Kualitas dan Resolusi Gambar terhadap Kinerja Model

Resolusi gambar yang cukup tinggi dan latar belakang bersih menjadi faktor penting dalam penelitian ini. Diskusi bisa berfokus pada bagaimana kualitas dan resolusi gambar memengaruhi performa model, serta pentingnya pra-pengolahan gambar, seperti normalisasi piksel dan pengubahan ukuran gambar, dalam meningkatkan efisiensi pelatihan dan stabilitas model.

#### 5.5. Implementasi dan Pengujian Model pada Dataset Uji

Pembagian dataset menjadi data pelatihan dan data uji dengan validation split memungkinkan evaluasi yang adil terhadap kemampuan model dalam mengklasifikasikan spesies daun yang belum pernah dilihat. Diskusi bisa mencakup peran dataset uji dalam mengukur seberapa baik model ini mampu menangani data baru dan apakah hasil yang dicapai cukup representatif untuk penggunaan di dunia nyata.

#### 5.6. Keterbatasan Penelitian dan Tantangan Masa Depan

Selain diskusi tentang keberhasilan model, penting juga untuk menyoroti keterbatasan yang ada, seperti keterbatasan pada variasi dataset daun, pencahayaan gambar, atau jumlah spesies yang diuji. Tantangan masa depan dapat mencakup pengembangan model yang lebih robust terhadap variasi kondisi pengambilan gambar dan peningkatan kemampuan segmentasi citra dalam skenario yang lebih kompleks.

### 6. KESIMPULAN

Penelitian ini menunjukkan bahwa penggunaan Convolutional Neural Network (CNN) dan teknik segmentasi citra dapat menjadi solusi yang efektif untuk pengelompokan spesies daun secara otomatis. Dengan kemampuan model CNN dalam mengekstraksi fitur-fitur penting dari daun dan segmentasi citra yang memungkinkan fokus pada objek daun, penelitian ini berhasil mencapai akurasi tinggi dalam klasifikasi spesies daun. Hal ini menunjukkan bahwa teknologi kecerdasan buatan dapat menjadi alat yang berguna dalam bidang botani dan konservasi lingkungan, terutama dalam identifikasi dan pelestarian spesies tumbuhan yang lebih efektif dan efisien.

### DAFTAR PUSTAKA

- [1] Rima Dias Ramadhani, A. Nur Aziz Thohari, C. Kartiko, A. Junaidi, T. Ginanjar Laksana, and N. Alim Setya Nugraha, "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 312–318, Apr. 2021, doi: 10.29207/resti.v5i2.2754.
- [2] M. Arsal, B. Agus Wardijono, and D. Anggraini, "Face Recognition Untuk Akses Pegawai Bank Menggunakan Deep Learning Dengan Metode CNN," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 6, no. 1, pp. 55–63, Jun. 2020, doi: 10.25077/teknosi.v6i1.2020.55-63.
- [3] M Mesran, Sitti Rachmawati Yahya, Fifto Nugroho, and Agus Perdana Windarto, "Investigating the Impact of ReLU and Sigmoid Activation Functions on Animal Classification Using CNN Models," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 8, no. 1, pp. 111–118, Feb. 2024, doi: 10.29207/resti.v8i1.5367.
- [4] M. Albani and R. R. Andhi, "Klasifikasi Uang Rupiah Kertas Tidak Layak Edar Menggunakan CNN Xception Transfer Learning Berbasis Website," vol. 8, no. 2, p. 2023
- [5] P. Nyoman and Putu Kusuma Negara, "Deteksi Masker Pencegahan Covid19 Menggunakan Convolutional Neural Network Berbasis Android," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 3, pp. 576–583, Jun. 2021, doi: 10.29207/resti.v5i3.3103.
- [6] S. Sheila, M. Kharil Anwar, A. B. Saputra, R. Pujiyanto, and I. P. Sari, "Deteksi Penyakit pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN)." [Online]. Available: <https://www.kaggle.com/datasets/tedisetiady/leaf->
- [7] I. Astuti, W. W. Ariestya, and B. Solehudin, "Deteksi Objek Daun Semanggi Secara Real Time Menggunakan CNN-Single Shot Multibox Detector (SSD)," *Jurnal Ilmiah FIFO*, vol. 14, no. 1, p. 47, May 2022, doi: 10.22441/fifo.2022.v14i1.005.
- [8] "558-1137-1-SM".
- [9] "4243-Article Text-16553-1-10-20220302".
- [10] I. Albanna, R. Tri Hadi Laksono, J. S. Informasi, T. Adhi, and T. Surabaya, "Implementasi Pandas Data frame sebagai Agregasi dan Tabulasi Penyajian Data Luaran Survei Kepuasan Pengguna Proses Pembelajaran dalam Pendidikan Tinggi."
- [11] Lia Farokhah, "Perbandingan Metode Deteksi Wajah Menggunakan OpenCV Haar Cascade, OpenCV Single Shot Multibox Detector (SSD) dan DLib CNN," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 3, pp. 609–614, Jun. 2021, doi: 10.29207/resti.v5i3.3125.



- [12] S. Adiningsi and R. A. Saputra, “JIP (Jurnal Informatika Polinema) IDENTIFIKASI JENIS DAUN TANAMAN OBAT MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN MODEL VGG16”.
- [13] S. K. Dirjen *et al.*, “Terakreditasi SINTA Peringkat 2,” *masa berlaku mulai*, vol. 1, no. 3, pp. 476–481, 2017.
- [14] D. Tamara *et al.*, “Tamara, Deteksi Keaslian Uang Kertas Berdasarkan Fitur Gray Level Co-Occurrence Matrix (GLCM) Menggunakan...105 Deteksi Keaslian Uang Kertas Berdasarkan Fitur Gray Level Co-Occurrence Matrix (GLCM) Menggunakan k-Nearest Neighbor.”
- [15] Mayanda Mega Santoni, Nurul Chamidah, Desta Sandya Prasvita, Helena Nurramdhani Irmada, Ria Astriratma, and Reza Amarta Prayoga, “Penerapan Convolutional Neural Networks untuk Mesin Penerjemah Bahasa Daerah Minangkabau Berbasis Gambar,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 6, pp. 1153–1160, Dec. 2021, doi: 10.29207/resti.v5i6.3614.