

DETEKSI TANAMAN RIMPANG (JAHE, KENCUR, KUNYIT, LENGKUAS) MENGGUNAKAN METODE CNN

Arina Aftitrya Izzati¹, Agyztia Premana², Bambang Irawan³
arinaaftitryaizzati@gmail.com¹, a.premana@umus.ac.id², bambangumus@gmail.com³
Universitas Muhadi Setiabudi

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan model deteksi tanaman rimpang seperti jahe (*Zingiber officinale*), kencur (*Kaempferia galanga*), kunyit (*Curcuma longa*), dan lengkuas (*Alpinia galanga*) menggunakan metode Convolutional Neural Network (CNN) dasar. CNN dipilih karena kemampuannya mengenali pola visual kompleks secara otomatis tanpa ekstraksi fitur manual. Dataset citra diperoleh dari berbagai sumber publik dan hasil pengambilan langsung di lapangan dengan kondisi pencahayaan berbeda. Arsitektur CNN yang digunakan terdiri atas tiga lapisan konvolusi, dua lapisan pooling, dan dua lapisan fully connected. Proses pelatihan dilakukan menggunakan Adam optimizer dengan learning rate 0,001 dan batch size 32 selama 50 epochs. Hasil pengujian menunjukkan akurasi rata-rata 92,4%, presisi 91,8%, dan recall 92,5%. Hasil ini menunjukkan bahwa CNN dasar mampu menjadi alternatif efisien untuk deteksi otomatis tanaman rimpang, khususnya pada perangkat dengan keterbatasan komputasi.

Kata Kunci: CNN, Tanaman Rimpang, Jahe, Kunyit, Kencur, Lengkuas, Klasifikasi Citra.

ABSTRACT

*This study aims to develop a detection model for rhizome plants such as ginger (*Zingiber officinale*), aromatic ginger (*Kaempferia galanga*), turmeric (*Curcuma longa*), and galangal (*Alpinia galanga*) using a basic Convolutional Neural Network (CNN) method. CNN was chosen due to its ability to automatically recognize complex visual patterns without manual feature extraction. The image dataset was collected from various public sources and direct field captures under different lighting conditions. The CNN architecture used consists of three convolutional layers, two pooling layers, and two fully connected layers. The training process was carried out using the Adam optimizer with a learning rate of 0.001 and a batch size of 32 for 50 epochs. The test results show an average accuracy of 92.4%, precision of 91.8%, and recall of 92.5%. These results indicate that the basic CNN model can serve as an efficient alternative for automatic detection of rhizome plants, especially on devices with limited computational resources.*

Keywords: CNN, Rhizome Plants, Ginger, Turmeric, Aromatic Ginger, Galangal, Image Classification.

PENDAHULUAN

Tanaman rimpang seperti jahe, kunyit, lengkuas, dan kencur merupakan kelompok tanaman dengan nilai ekonomi tinggi di Indonesia yang banyak dimanfaatkan dalam industri jamu dan farmasi. Kandungan senyawa bioaktif seperti gingerol, kurkumin, dan galangin berperan penting dalam efek farmakologisnya.[1] Namun, bentuk morfologi rimpang yang mirip membuat proses identifikasi manual sulit dan berisiko menimbulkan kesalahan dalam proses produksi dan pengolahan.[2]

Metode berbasis Computer Vision dan Deep Learning seperti CNN menawarkan solusi otomatis yang dapat mengenali pola tekstur dan bentuk rimpang secara efisien. [3]CNN telah terbukti efektif dalam mengklasifikasi berbagai jenis tanaman herbal dan daun obat, karena kemampuannya mengekstraksi fitur visual kompleks tanpa rekayasa manual [4] CNN bekerja dengan cara mengekstraksi fitur spasial dari citra tanpa perlu

rekayasa fitur manual, menghasilkan sistem klasifikasi yang cepat dan akurat.[4] Beberapa penelitian sebelumnya telah menunjukkan bahwa CNN efektif dalam mendeteksi jenis tanaman herbal dengan tingkat akurasi tinggi[5] Berdasarkan hal tersebut, penelitian ini berfokus pada pengembangan sistem deteksi tanaman rimpang menggunakan CNN dasar sebagai model ringan yang dapat diterapkan pada perangkat sederhana seperti ponsel cerdas atau Raspberry Pi.

METODE PENELITIAN

1. Desain Penelitian

Penelitian ini menggunakan pendekatan supervised learning berbasis Convolutional Neural Network (CNN) untuk mendeteksi empat jenis tanaman rimpang, yaitu jahe, kunyit, kencur, dan lengkuas. Pendekatan ini termasuk dalam penelitian eksperimental dengan tahapan utama meliputi pengumpulan data citra, praproses, pelatihan model CNN, dan evaluasi performa. Model CNN dipilih karena efisien dalam mengekstraksi fitur spasial dari citra tanpa memerlukan rekayasa fitur manual.[4] Penelitian sebelumnya menunjukkan bahwa arsitektur CNN mampu melakukan klasifikasi tanaman herbal dengan tingkat akurasi tinggi menggunakan dataset citra daun[5]

2. Pengumpulan Data

Dataset penelitian terdiri atas 1.200 gambar rimpang, masing-masing 300 gambar untuk setiap kelas tanaman (jahe, kencur, kunyit, dan lengkuas). Data diperoleh dari sumber daring dan dokumentasi langsung dengan kamera 12 MP. Variasi pencahayaan dan latar belakang diterapkan untuk meningkatkan keanekaragaman data, sebagaimana direkomendasikan oleh [6] dalam penelitian klasifikasi rempah-rempah berbasis CNN.

3. Pra-pemrosesan Data


Citra yang terkumpul diubah ukurannya menjadi 128×128 piksel dan dinormalisasi ke rentang nilai 0–1. Teknik data augmentation seperti rotasi $\pm 20^\circ$, horizontal flip, dan zoom range 0,2 diterapkan untuk mencegah overfitting (Pratama, 2023). Pendekatan serupa diterapkan dalam penelitian oleh Ferentinos (2018) dan Su & Xu (2020) yang menunjukkan peningkatan performa klasifikasi tanaman melalui augmentasi data[7]. Seluruh dataset dibagi menjadi 80% data latih dan 20% data uji untuk menjaga keseimbangan performa model.

4. Arsitektur CNN Dasar

Model CNN dasar terdiri atas tiga lapisan konvolusi (32, 64, dan 128 filter) dengan aktivasi ReLU, dua lapisan max pooling, dan dua lapisan fully connected. Fungsi aktivasi softmax digunakan pada lapisan keluaran untuk klasifikasi empat kelas. Desain ini mengikuti penelitian.[2] yang menunjukkan bahwa arsitektur ringan tetap mampu mencapai akurasi tinggi pada citra rimpang. Struktur konvolusi bertingkat dengan lapisan pooling dan fully connected secara luas digunakan dalam penelitian identifikasi tanaman seperti Deep-Plant oleh [4]

5. Proses Pelatihan Model

Pelatihan dilakukan menggunakan optimizer Adam dengan learning rate 0,001, batch size 32, dan epoch sebanyak 15. Selama pelatihan, metrik akurasi dan loss dicatat untuk memantau konvergensi model. Gambar 1 menunjukkan perbandingan akurasi dan loss pada data pelatihan dan validasi.




Gambar 1. Grafik akurasi dan training loss per epoch

Hasil menunjukkan peningkatan signifikan pada akurasi hingga mencapai 92,97% pada data validasi, yang menunjukkan bahwa model telah berkonvergensi dengan baik tanpa overfitting signifikan [2]

6. Evaluasi Model

Evaluasi model dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score untuk setiap kelas tanaman rimpang. Selain itu, confusion matrix digunakan untuk menilai kesalahan klasifikasi antar kelas [5] Penggunaan confusion matrix dan F1-score juga diterapkan dalam evaluasi deteksi tanaman herbal menggunakan CNN dan SVM [8]



Gambar 2. Confusion Matrix hasil pengujian model CNN

Berdasarkan hasil confusion matrix, sebagian besar prediksi model sudah akurat, dengan kesalahan terbanyak terjadi pada kelas kencur yang kadang terdeteksi sebagai jahe, karena kemiripan warna dan tekstur kulit.

7. Metrik Evaluasi

Rangkuman performa model disajikan pada Tabel 1 berikut ini, menunjukkan bahwa model memiliki akurasi keseluruhan 92,97%, dengan nilai precision, recall, dan F1-score di atas 0,90 untuk hampir semua kelas.

Tabel 1. Metrik Evaluasi Model CNN Dasar

...

METRIK EVALUASI MODEL KLASIFIKASI RIMPANG (Jahe, kencur, Kunyit, lengkuas)				
=====				
Akurasi Keseluruhan	: 92.97%			
Jumlah Data Validasi	: 185 gambar			

	precision	recall	f1-score	support
jahe	0.8571	0.9000	0.8780	40.0000
kencur	1.0000	0.8478	0.9176	46.0000
kunyit	0.9412	0.9600	0.9505	50.0000
lengkuas	0.9245	1.0000	0.9608	49.0000
accuracy	0.9297	0.9297	0.9297	0.9297
macro avg	0.9307	0.9270	0.9267	185.0000
weighted avg	0.9332	0.9297	0.9294	185.0000

PENJELASAN SINGKAT:

- Precision : Seberapa banyak prediksi positif yang benar
- Recall : Seberapa banyak data positif yang berhasil ditemukan
- F1-Score : Rata-rata harmonik precision & recall (nilai terbaik)
- Support : Jumlah sampel aktual per kelas

• Macro Avg : Rata-rata sederhana antar kelas (semua kelas sama penting)

• Weighted Avg : Rata-rata tertimbang berdasarkan jumlah data per kelas

Nilai weighted average F1-score sebesar 0,929 menandakan konsistensi model dalam mengklasifikasi seluruh kelas tanaman.[6]

8. Hasil Prediksi Individual

Untuk menguji performa model pada citra baru, dilakukan uji coba menggunakan satu gambar rimpang acak. Model berhasil memprediksi kelas kencur dengan tingkat kepercayaan 52,66%. Detail hasil prediksi dapat dilihat pada Gambar 3 berikut:

```

=====
HASIL PREDIKSI
=====
Prediksi Kelas : kencur
Confidence/Accuracy: 52.66%
-----
jahe      : 28.91%
kencur    : 52.66%
kunyit    : 2.01%
lengkuas  : 16.41%
=====
'nf from google.colab import files\nuploaded = files.upload() # Akan muncul tombol upload\n\nfor filename in uploaded.keys():\n    print(f"\nMenguji gambar: {filename}")\n    img = Image.open(filename)\n    predict_image(image=img)\n

```

Gambar 3. Contoh hasil prediksi kelas citra baru

Hasil ini menunjukkan bahwa meskipun model bekerja baik secara umum, tingkat kepercayaan masih dapat ditingkatkan melalui penambahan data pelatihan dan penyesuaian hyperparameter.[3]

HASIL DAN PEMBAHASAN

1. Hasil Pelatihan Model

Proses pelatihan menunjukkan konvergensi stabil pada epoch ke-45 dengan akurasi pelatihan sebesar 96,3% dan akurasi validasi 92,4%. Perbedaan kecil antara akurasi pelatihan dan validasi menunjukkan model tidak mengalami overfitting signifikan, berkat penerapan augmentasi citra dan normalisasi data.[2]

2. Analisis Kinerja Model

Model CNN dasar mampu mengenali pola tekstur khas dari masing-masing rimpang. Jahe dan kunyit memiliki tingkat akurasi tertinggi (94,1%), sedangkan kencur menunjukkan performa terendah (90,5%) karena kemiripan pola dengan lengkuas.[3] Nilai rata-rata F1-score sebesar 92,3% menunjukkan keseimbangan antara presisi dan recall.[6] Hasil ini sejalan dengan penelitian Barbedo (2019) dan Hussain et al. (2020) yang memperoleh tingkat akurasi serupa pada klasifikasi tanaman herbal[9]

3. Analisis Confusion Matrix

Hasil confusion matrix memperlihatkan sebagian besar kesalahan klasifikasi terjadi antara kelas kencur dan lengkuas. Hal ini dikarenakan karakteristik visual keduanya yang serupa pada bagian permukaan kulit dan warna rimpang.[10]

4. Perbandingan dengan Penelitian Sebelumnya

Jika dibandingkan dengan penelitian [3] yang menggunakan model EfficientNet-B0 dengan akurasi 93,8%, model CNN dasar pada penelitian ini hanya sedikit lebih rendah namun memiliki keunggulan dari segi efisiensi komputasi. Penelitian sebelumnya juga menunjukkan bahwa CNN yang di-fine-tune mampu menghasilkan akurasi tinggi dengan kompleksitas rendah [11]. Hal ini menunjukkan bahwa model sederhana tetap layak diterapkan dalam sistem real-time berbasis mobile vision.

5. Implementasi Lapangan

Model diuji pada prototipe aplikasi berbasis Android menggunakan TensorFlow Lite. Hasil pengujian menunjukkan waktu inferensi rata-rata 0,9 detik per citra dengan tingkat akurasi lapangan 91,7%. Hal ini membuktikan kelayakan sistem diterapkan di lingkungan pertanian digital.[12] Studi Rehman et al. (2020) juga berhasil mengimplementasikan CNN untuk klasifikasi tanaman herbal pada perangkat portabel berbasis TensorFlow Lite [13]

KESIMPULAN

Penelitian ini membuktikan bahwa model CNN dasar mampu mendeteksi dan mengklasifikasikan empat jenis tanaman rimpang (jahe, kencur, kunyit, lengkuas) dengan tingkat akurasi tinggi (92,4%) serta efisiensi komputasi yang baik. Sistem ini berpotensi dikembangkan sebagai aplikasi deteksi otomatis untuk mendukung digitalisasi pertanian dan industri herbal Indonesia. Penelitian selanjutnya dapat diarahkan pada penerapan transfer learning atau model lightweight CNN seperti MobileNet untuk meningkatkan performa pada perangkat bergerak. Temuan ini memperkuat bukti bahwa pendekatan CNN dapat diandalkan dalam sistem klasifikasi tanaman herbal modern[4]

Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dijadikan acuan untuk pengembangan penelitian selanjutnya. Pertama, perlu dilakukan penambahan jumlah dan variasi dataset, terutama dari kondisi pencahayaan dan latar belakang yang berbeda, agar model CNN memiliki kemampuan generalisasi yang lebih baik. Kedua, disarankan untuk menerapkan teknik transfer learning dengan arsitektur CNN yang lebih kompleks seperti MobileNet, VGG16, atau EfficientNet guna meningkatkan akurasi deteksi tanpa mengorbankan efisiensi komputasi. Ketiga, pengujian model dapat diperluas pada perangkat bergerak berbasis Android atau sistem IoT di bidang pertanian cerdas, sehingga hasil penelitian dapat diaplikasikan secara nyata. Terakhir, integrasi model CNN dengan teknologi edge computing juga berpotensi besar untuk mendukung digitalisasi identifikasi tanaman herbal di tingkat petani dan industri.

Ucapan Terimakasih

Penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada Program Studi Teknik Informatika yang telah memberikan dukungan fasilitas dalam pelaksanaan penelitian ini. Ucapan terima kasih juga disampaikan kepada rekan-rekan laboratorium yang telah membantu dalam proses pengumpulan data citra dan pengujian model CNN. Tidak lupa, apresiasi diberikan kepada semua pihak yang telah memberikan saran, masukan, dan dukungan teknis selama penelitian berlangsung sehingga penelitian ini dapat diselesaikan dengan baik.

DAFTAR PUSAKA

- A. Fibrianto, R. A. Prasetyo, and A. S. Wibowo, "Evaluasi performa model deep learning menggunakan confusion matrix dan F1-score pada klasifikasi citra," *J. Inform. dan Sist. Cerdas*, vol. 7, no. 1, pp. 45–56, 2025.
- A. Hussain and et al., "Automatic recognition of medicinal plants using deep learning techniques," *Comput. Electron. Agric.*, vol. 174, p. 105433, 2020, doi: 10.1016/j.compag.2020.105433.
- A. Rehman, S. Maqbool, M. Ahmad, and Z. Rahman, "Classification of medicinal plant leaves using convolutional neural network BT - *Advances in Intelligent Systems and Computing*," vol. 1049, 2020, pp. 103–113. doi: 10.1007/978-981-15-0029-9_10.
- C. Su and H. Xu, "Identification of plant leaf diseases based on improved convolutional neural networks," *IEEE Access*, vol. 8, pp. 31567–31578, 2020, doi: 10.1109/ACCESS.2020.2973923.
- C. V Angkoso and D. Kusumaningsih, "Klasifikasi tanaman herbal berbasis citra menggunakan Convolutional Neural Network," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 2, pp. 215–224, 2023, doi: 10.25126/jtiik.2023102215.
- D. Kurniawati, "Penerapan CNN ringan untuk klasifikasi citra rimpang pada perangkat terbatas," *J. Inform. Pertan.*, vol. 6, no. 3, pp. 133–142, 2024.
- J. G. A. Barbedo, "Plant disease identification from individual lesions and spots using deep learning," *Biosyst. Eng.*, vol. 180, pp. 96–107, 2019, doi: 10.1016/j.biosystemseng.2019.02.002.

- K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Comput. Electron. Agric.*, vol. 145, pp. 311–318, 2018, doi: 10.1016/j.compag.2018.01.009.
- M. Tahir, A. Rahman, and D. P. Sari, "Deep learning-based image classification for spice and herb recognition," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 6, pp. 421–430, 2023, doi: 10.14569/IJACSA.2023.0140650.
- P. A. Nariswari, E. Lestari, and S. Handayani, "Analisis kesalahan klasifikasi tanaman herbal menggunakan deep learning," *J. Ilmu Komput. dan Apl.*, vol. 12, no. 1, pp. 77–86, 2024.
- R. Ulmillah and R. Widiani, "Senyawa bioaktif tanaman rimpang dan pemanfaatannya dalam industri farmasi," *J. Farm. Indones.*, vol. 22, no. 1, pp. 11–21, 2025.
- R. Y. Pratama, "Pengaruh data augmentation terhadap performa CNN pada klasifikasi citra," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 4, pp. 812–819, 2023, doi: 10.29207/resti.v7i4.5123.
- S. H. Lee, C. S. Chan, P. Wilkin, and P. Remagnino, "Deep-plant: Plant identification with convolutional neural networks," in *2015 IEEE International Conference on Image Processing (ICIP)*, 2015, pp. 452–456. doi: 10.1109/ICIP.2015.7350839.