

Klasifikasi Varietas Daun Singkong Menggunakan *NASNet Mobile* pada Dataset Tidak Seimbang

^{1*}Umi Roziqoh, ²Made Ayu Dusea Widyadara, ³Daniel Swanjaya

^{1, 2, 3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹umiroziqoh03@gmail.com, ²madedara@gmail.com, ³daniel@unpkediri.ac.id

Penulis Korespondens : Umi Roziqoh

Abstrak—Daun singkong merupakan salah satu komoditas pertanian yang memiliki nilai gizi dan ekonomi tinggi sehingga identifikasi jenis daun singkong menjadi penting untuk mendukung pemanfaatan dan budidaya yang tepat. Namun, proses identifikasi secara manual sering mengalami kesalahan akibat kemiripan karakteristik visual antar jenis daun. Penelitian ini bertujuan menganalisis performa arsitektur *NASNet Mobile* dalam mengklasifikasikan jenis daun singkong secara otomatis pada dataset yang tidak seimbang. Dataset terdiri dari tiga kelas, yaitu daun singkong karet, daun singkong papua, dan daun singkong sayur. Sebelum proses pelatihan, data melalui tahap preprocessing berupa normalisasi dan resize citra, serta augmentasi untuk meningkatkan kualitas dan variasi data. Model dilatih menggunakan arsitektur *NASNet Mobile* dan dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa model *NASNet Mobile* memperoleh akurasi sebesar 94% dengan weighted average precision sebesar 0,94, recall sebesar 0,94, dan *F1-score* sebesar 0,94. Hasil tersebut menunjukkan bahwa *NASNet Mobile* mampu melakukan klasifikasi jenis daun singkong.

Kata Kunci—Deep learning, klasifikasi citra, *NASNet Mobile*, daun singkong

Abstract—Cassava leaves are an agricultural commodity with high nutritional and economic value, making leaf type identification important for supporting proper utilization and cultivation. However, manual identification often results in errors due to the similarity of visual characteristics among leaf types. This study aims to analyze the performance of the *NASNet Mobile* architecture in automatically classifying cassava leaf types using an imbalanced dataset. The dataset consists of three classes: rubber cassava leaves, Papua cassava leaves, and vegetable cassava leaves. Prior to training, the data underwent preprocessing, including normalization and image resizing, as well as data augmentation to improve quality and diversity. The model was evaluated using accuracy, precision, recall, and F1-score metrics. The results showed that *NASNet Mobile* achieved an accuracy of 94%, with a weighted average precision, recall, and F1-score of 0.94. These findings indicate that *NASNet Mobile* is effective for cassava leaf classification.

Keywords—Deep learning, image classification, *NASNet Mobile*, cassava leaves leaf,

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Daun singkong (*Manihot esculenta*) merupakan salah satu tanaman pangan yang banyak dimanfaatkan masyarakat Indonesia karena memiliki kandungan nutrisi yang tinggi dan nilai ekonomi yang cukup besar. Selain digunakan sebagai bahan pangan, daun singkong juga dimanfaatkan sebagai pakan ternak serta bahan baku industri pengolahan pangan[1]. Pemanfaatan tanaman singkong terus meningkat seiring dengan kebutuhan pangan dan pakan yang semakin

tinggi[2]. Oleh karena itu, identifikasi jenis daun singkong menjadi penting untuk membantu proses budidaya maupun pemanfaatannya secara tepat[3].

Namun, proses identifikasi jenis daun singkong masih banyak dilakukan secara manual berdasarkan pengamatan visual. Beberapa jenis daun singkong memiliki bentuk, warna, dan pola tulang daun yang mirip sehingga sering menimbulkan kesalahan identifikasi, terutama bagi masyarakat awam atau petani yang belum memiliki pengalaman khusus[4]. Kesalahan identifikasi dapat mempengaruhi pemanfaatan tanaman singkong karena setiap varietas memiliki karakteristik dan fungsi yang berbeda. Oleh sebab itu, diperlukan suatu sistem otomatis yang mampu membantu proses klasifikasi jenis daun singkong secara lebih cepat dan objektif[5].

Perkembangan teknologi kecerdasan buatan, khususnya dalam bidang pengolahan citra digital, memberikan peluang untuk menyelesaikan permasalahan tersebut. Salah satu metode yang banyak digunakan adalah *Convolutional Neural Network* (CNN), yaitu metode *deep learning* yang mampu mengenali pola visual pada citra secara otomatis[6]. CNN telah banyak diterapkan pada berbagai penelitian klasifikasi tanaman dan identifikasi daun karena memiliki kemampuan ekstraksi fitur yang baik[7].

Beberapa penelitian sebelumnya telah menerapkan arsitektur CNN pada klasifikasi daun maupun penyakit tanaman. Penelitian oleh Arafat dkk. menggunakan arsitektur MobileNet untuk klasifikasi penyakit daun singkong dan memperoleh akurasi validasi sebesar 84%[3]. Penelitian lain menggunakan arsitektur VGG16 berbasis Android untuk klasifikasi penyakit daun singkong dan menghasilkan akurasi sebesar 96%[8]. Selain itu, Fuadi dan Suharso menggunakan arsitektur *NASNet Mobile* untuk klasifikasi penyakit daun kentang dan memperoleh hasil klasifikasi yang baik dibandingkan beberapa model ringan lainnya[9]. Penelitian Hardi juga melakukan komparasi MobileNet dan *NASNet Mobile* pada klasifikasi penyakit daun teh, di mana *NASNet Mobile* menunjukkan kemampuan klasifikasi yang kompetitif[10].


Meskipun berbagai penelitian sebelumnya menunjukkan hasil yang baik, sebagian besar penelitian masih berfokus pada klasifikasi penyakit daun dan menggunakan dataset yang relatif seimbang. Penelitian mengenai klasifikasi jenis daun singkong berdasarkan varietas masih terbatas, terutama pada kondisi dataset yang tidak seimbang. Tidak seimbangan data dapat menyebabkan model lebih cenderung mengenali kelas mayoritas dibandingkan kelas minoritas sehingga menurunkan kemampuan generalisasi model. Selain itu, kemiripan visual antar jenis daun singkong juga menjadi tantangan tersendiri dalam proses klasifikasi karena model dapat mengalami kesulitan dalam membedakan karakteristik setiap kelas secara konsisten.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penggunaan arsitektur *NASNet Mobile* untuk klasifikasi jenis daun singkong yang terdiri dari daun singkong karet, papua, dan sayur. *NASNet Mobile* dipilih karena memiliki ukuran model yang ringan, proses inferensi yang cepat, dan kemampuan ekstraksi fitur yang baik sehingga sesuai digunakan untuk pengolahan citra pada perangkat dengan sumber daya terbatas[11]. Penggunaan *NASNet Mobile* diharapkan mampu membantu proses klasifikasi daun singkong secara lebih cepat dan objektif melalui pemanfaatan fitur visual pada citra daun.

Penelitian ini bertujuan untuk menganalisis performa arsitektur *NASNet Mobile* dalam mengklasifikasikan jenis daun singkong pada dataset yang tidak seimbang menggunakan metrik evaluasi berupa akurasi, *precision*, *recall*, dan *F1-score*. Penelitian ini diharapkan dapat menjadi langkah awal dalam pengembangan sistem identifikasi daun singkong secara otomatis guna membantu meningkatkan efisiensi dan mengurangi kesalahan identifikasi pada bidang pertanian.

II. METODE

Pada penelitian ini digunakan pendekatan komprehensif untuk melakukan klasifikasi jenis daun singkong. Proses penelitian mencakup beberapa tahapan utama, yaitu pengumpulan data, *preprocessing* data, augmentasi citra, pelatihan model menggunakan arsitektur *NASNet Mobile*, serta evaluasi performa model. Alur penelitian yang digunakan pada penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

A. Pengumpulan Data

Pengumpulan data merupakan tahap awal dalam penelitian yang dilakukan untuk memperoleh dataset citra daun singkong yang akan digunakan pada proses pelatihan dan pengujian model. Data yang dikumpulkan tidak hanya berupa citra mentah, tetapi juga dipersiapkan melalui beberapa tahapan agar siap digunakan dalam proses pengolahan dan analisis lebih lanjut. Pada penelitian ini, dataset terdiri dari total 182 citra daun singkong yang terbagi ke dalam tiga kelas, yaitu 33 daun singkong karet, 88 daun singkong Papua, dan 61 daun singkong sayur. Data citra diperoleh melalui proses pengambilan gambar menggunakan kamera smartphone dengan variasi kondisi pencahayaan dan sudut pengambilan gambar untuk meningkatkan keberagaman dataset.

Tabel 1. Dataset

		
Daun Singkong Sayur	Daun Singkong Karet	Daun Singkong Papua

B. *Preprocessing* Data

Sebelum proses pelatihan model dilakukan, seluruh citra daun singkong melewati tahap *preprocessing* yang terdiri dari normalisasi dan *resize* citra. Normalisasi bertujuan untuk menyederhanakan rentang nilai piksel sehingga proses komputasi menjadi lebih stabil dan efisien.

Selain itu, proses *resize* dilakukan dengan mengubah ukuran citra menjadi dimensi yang seragam agar sesuai dengan arsitektur model yang digunakan[12].



Gambar 2. Daun awal

Tahap *preprocessing* data dilakukan dengan menormalisasi seluruh citra daun singkong serta menyeragamkan ukuran citra menjadi 224×224 piksel. Normalisasi dilakukan dengan mengonversi nilai piksel dari rentang 0–255 ke rentang 0–1 untuk meningkatkan efisiensi proses pengolahan data dan pelatihan model.



Gambar 3. Data setelah di normalisasi dan resize

Jumlah dataset yang masih terbatas menyebabkan perlunya dilakukan augmentasi citra guna meningkatkan variasi data pelatihan seperti pada Gambar 3. Selanjutnya, seluruh citra diubah ukurannya menjadi 224×224 piksel untuk menyeragamkan dimensi input sesuai dengan kebutuhan arsitektur *NASNet Mobile*. Keceragaman ukuran citra membantu proses pelatihan model agar berjalan lebih optimal dan stabil.

C. Augmentasi Citra

Jumlah data yang masih terbatas pada penelitian ini menyebabkan perlunya dilakukan augmentasi citra untuk meningkatkan keberagaman dataset. Augmentasi data merupakan proses menghasilkan variasi citra baru dari dataset asli melalui beberapa teknik transformasi[13]. Teknik augmentasi yang diterapkan meliputi rotasi, pembalikan horizontal dan vertikal, *zooming*, penyesuaian kecerahan, *shearing*, *shifting*, penambahan *Gaussian noise*, *blurring*, dan penyesuaian kontras.

Pada penelitian ini, augmentasi citra dilakukan menggunakan beberapa teknik transformasi, yaitu rotasi hingga 40°, pembalikan horizontal dan vertikal, *zooming* sebesar 80–120%, penyesuaian kecerahan sebesar 0,5–1,5, *shearing* hingga 20°, serta *shifting* horizontal dan vertikal hingga 20%. Selain itu, diterapkan pula penambahan *Gaussian noise*, *Gaussian blur*, dan penyesuaian kontras sebesar 0,8–1,2 guna meningkatkan keberagaman data citra. Proses augmentasi menghasilkan dataset baru dengan jumlah data yang lebih banyak dibandingkan dataset awal.




Gambar 4. Data setelah di augmentasi

Dari proses augmentasi, dataset menjadi lebih beragam sehingga membantu model dalam mengenali berbagai karakteristik visual jenis daun singkong. Augmentasi yang dilakukan menghasilkan variasi citra melalui perubahan orientasi, pencahayaan, skala, serta kondisi visual lainnya, sehingga model dapat belajar dari data yang lebih representatif. Akibat proses augmentasi tersebut, jumlah dataset meningkat menjadi 1.940 citra yang terdiri atas 880 citra daun singkong papua, 610 citra daun singkong sayur, dan 450 citra daun singkong karet. Peningkatan jumlah dan variasi data ini membantu model dalam membedakan karakteristik masing-masing jenis daun singkong serta meningkatkan kemampuan generalisasi model terhadap berbagai kondisi citra. Dengan demikian, model diharapkan mampu melakukan klasifikasi jenis daun singkong secara lebih akurat meskipun citra mengalami variasi pencahayaan, sudut pengambilan gambar, maupun kualitas visual.

D. Modelling

Pada penelitian ini digunakan metode *Deep Learning* berbasis *Convolutional Neural Network* (CNN) untuk proses klasifikasi citra daun singkong. CNN merupakan metode pembelajaran mendalam yang mampu melakukan ekstraksi fitur secara otomatis pada citra sehingga efektif digunakan dalam berbagai tugas klasifikasi gambar. Model yang digunakan adalah NASNet Mobile (*Neural Architecture Search Network*), yaitu arsitektur CNN yang telah dilatih menggunakan dataset ImageNet. NASNet Mobile memiliki struktur jaringan yang dioptimalkan menggunakan pendekatan *Reinforcement Learning* sehingga mampu memberikan performa klasifikasi yang baik dengan kebutuhan komputasi yang lebih efisien[14].



Gambar 5. Arsitektur NASNet Mobile[15]

Arsitektur NASNet Mobile diawali dengan *input layer* yang menerima citra berwarna dengan tiga kanal (*RGB*). Selanjutnya, citra diproses melalui lapisan konvolusi awal untuk mengekstraksi fitur dasar seperti tepi, tekstur, dan warna. Setelah itu, jaringan terdiri dari dua blok utama, yaitu *Reduction Cell* dan *Normal Cell*. *Reduction Cell* berfungsi untuk mengurangi dimensi spasial fitur sehingga proses komputasi menjadi lebih efisien tanpa menghilangkan informasi penting pada citra.

Sementara itu, *Normal Cell* digunakan untuk memperkuat proses ekstraksi fitur tanpa mengubah ukuran dimensi citra. Blok ini diulang beberapa kali untuk menghasilkan representasi fitur yang lebih kompleks. Fitur yang telah diekstraksi kemudian diteruskan ke *Fully Connected Layer* untuk mengubah fitur menjadi vektor satu dimensi. Selanjutnya, *Softmax Layer* digunakan untuk menghasilkan probabilitas setiap kelas sehingga diperoleh hasil klasifikasi akhir. *NASNet Mobile* memiliki kemampuan menghasilkan performa klasifikasi yang baik dengan kebutuhan komputasi yang relatif ringan sehingga cocok digunakan pada perangkat mobile maupun sistem dengan sumber daya terbatas[15].

Hasil pelatihan menunjukkan akurasi pelatihan mencapai 98,75%, sedangkan akurasi validasi mencapai 96,42%. Perbedaan nilai akurasi yang relatif kecil menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting secara signifikan. Proses pelatihan berlangsung selama 10 epoch dengan optimizer Adam dan learning rate 0,001. Hasil evaluasi pada data pengujian menghasilkan akurasi sebesar 95,83%, sehingga model *NASNet Mobile* dinilai mampu melakukan klasifikasi jenis daun singkong dengan baik.

E. Matriks Evaluasi Model

Untuk mengetahui tingkat keberhasilan kinerja model dalam mengklasifikasikan citra daun singkong, digunakan beberapa metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. *Confusion matrix* merupakan tabel evaluasi yang digunakan untuk membandingkan hasil prediksi model dengan label sebenarnya sehingga dapat diketahui jumlah prediksi benar maupun salah pada setiap kelas[8].

Tabel 2. *Confusion Matrix*

Class	Kelas Positif	Kelas Negatif
Positif	TP (True Positive)	TN (True Negative)
Negatif	FP (False Positive)	FN (False Negative)

$$Akurasi = \frac{(TP+TN)}{(TP+FP+TN)} \quad (1)$$

$$Precision = \frac{(TP)}{(TP+FP)} \quad (2)$$

$$Recall = \frac{(TP)}{(TP+FN)} \quad (3)$$

$$F1 - Score = \frac{(2 \times recall \times presisi)}{(recall + presisi)} \quad (4)$$

III. HASIL DAN PEMBAHASAN

A. Confusion Matrix

Kinerja model NASNet Mobile dievaluasi melalui serangkaian pengujian menggunakan data uji yang telah dipisahkan sebelumnya. Evaluasi dilakukan dengan menerapkan *Confusion Matrix* guna menganalisis kemampuan model dalam mengklasifikasikan jenis daun singkong secara tepat. Nilai yang dihasilkan pada Confusion Matrix digunakan untuk menghitung metrik evaluasi berupa *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik-metrik tersebut memberikan informasi mengenai tingkat ketepatan prediksi, kemampuan model dalam mengenali setiap kelas, serta keseimbangan performa klasifikasi secara keseluruhan. Hasil evaluasi ini digunakan sebagai dasar untuk menilai efektivitas arsitektur *NASNet Mobile* dalam melakukan klasifikasi jenis daun singkong.

		Confusion Matrix		
Actual	daun_singkong_karet	60	6	7
	daun_singkong_papua	1	122	2
	daun_singkong_sayur	0	1	92
		daun_singkong_karet	daun_singkong_papua	daun_singkong_sayur
		Predicted		

Gambar 6. Hasil *Confusion Matrix*

Confusion Matrix pada Gambar 6 menunjukkan kemampuan model *NASNet Mobile* dalam mengklasifikasikan tiga jenis daun singkong, yaitu daun singkong karet, daun singkong papua, dan daun singkong sayur. Pada kelas daun singkong karet, model berhasil mengklasifikasikan sebanyak 60 citra dengan benar. Namun, masih terdapat 6 citra yang salah diklasifikasikan sebagai daun singkong papua dan 7 citra sebagai daun singkong sayur. Kesalahan ini kemungkinan disebabkan oleh kemiripan karakteristik visual antar jenis daun, seperti bentuk lobus dan pola tulang daun.

Pada kelas daun singkong papua, model menunjukkan performa yang sangat baik dengan 122 citra berhasil diklasifikasikan secara tepat. Hanya terdapat 1 citra yang salah dikenali sebagai daun singkong karet dan 2 citra sebagai daun singkong sayur. Hasil ini menunjukkan bahwa daun singkong papua memiliki karakteristik visual yang cukup khas sehingga lebih mudah dikenali oleh model.

Sementara itu, pada kelas daun singkong sayur, model mampu mengklasifikasikan 92 citra dengan benar. Kesalahan klasifikasi pada kelas ini relatif rendah, yaitu hanya 1 citra yang

diprediksi sebagai daun singkong papua, sedangkan tidak terdapat citra yang salah diklasifikasikan sebagai daun singkong karet.

Secara keseluruhan, hasil *Confusion Matrix* menunjukkan bahwa model *NASNet Mobile* memiliki kemampuan dalam membedakan ketiga jenis daun singkong. Sebagian besar citra berhasil diklasifikasikan dengan benar yang ditunjukkan oleh dominasi nilai pada diagonal utama matriks. Meskipun masih terdapat beberapa kesalahan klasifikasi, terutama pada kelas daun singkong karet, jumlah kesalahan tersebut relatif kecil dibandingkan jumlah prediksi yang benar. Hasil ini mengindikasikan bahwa model memiliki tingkat generalisasi yang baik dan mampu mengenali karakteristik visual masing-masing jenis daun singkong secara efektif.

B. Performa Model

Table 3. Performa Model (*Precision*, *Recall*, dan *F1-score*)

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Support
<i>daun_singkong_karet</i>	0.98	0.82	0.90	73
<i>daun_singkong_papua</i>	0.95	0.98	0.96	125
<i>daun_singkong_sayur</i>	0.91	0.99	0.95	93
<i>accuracy</i>			0.94	291
<i>macro avg</i>	0.95	0.93	0.93	291
<i>weighted avg</i>	0.94	0.94	0.94	291

Berdasarkan Tabel 3, hasil evaluasi model *NASNet Mobile* menunjukkan performa yang sangat baik dalam mengklasifikasikan tiga jenis daun singkong berdasarkan metrik *precision*, *recall*, *f1-score*, dan *accuracy*. Secara keseluruhan, model memperoleh akurasi sebesar 94% pada 291 data uji. Hasil ini menunjukkan bahwa model mampu mengenali dan membedakan jenis daun singkong dengan tingkat ketepatan yang tinggi, meskipun masih terdapat beberapa kesalahan klasifikasi pada beberapa kelas.

Pada kelas daun singkong karet, model memperoleh *precision* sebesar 0,98, *recall* sebesar 0,82, dan *f1-score* sebesar 0,90 dengan jumlah data uji sebanyak 73 citra. Nilai *precision* yang tinggi menunjukkan bahwa hampir seluruh prediksi yang dihasilkan untuk kelas daun singkong karet merupakan prediksi yang benar. Namun, nilai *recall* yang lebih rendah mengindikasikan bahwa masih terdapat beberapa citra daun singkong karet yang salah diklasifikasikan ke kelas lain.

Untuk kelas daun singkong papua, model menunjukkan performa yang sangat baik dengan *precision* sebesar 0,95, *recall* sebesar 0,98, dan *f1-score* sebesar 0,96 pada 125 data uji. Nilai *recall* yang tinggi menunjukkan bahwa hampir seluruh citra daun singkong papua berhasil dikenali dengan benar oleh model. Selain itu, nilai *precision* yang tinggi mengindikasikan bahwa sebagian besar prediksi pada kelas ini juga sesuai dengan label sebenarnya.

Sementara itu, pada kelas daun singkong sayur, model memperoleh *precision* sebesar 0,91, *recall* sebesar 0,99, dan *f1-score* sebesar 0,95 dengan jumlah 93 data uji. Nilai *recall* yang mendekati sempurna menunjukkan bahwa hampir seluruh citra daun singkong sayur berhasil diklasifikasikan dengan benar. Meskipun demikian, nilai *precision* yang sedikit lebih rendah

menunjukkan masih adanya sejumlah kecil citra dari kelas lain yang diprediksi sebagai daun singkong sayur.

Nilai *macro average* sebesar 0,95 untuk *precision*, 0,93 untuk *recall*, dan 0,93 untuk *f1-score* menunjukkan bahwa performa model relatif seimbang pada seluruh kelas tanpa mempertimbangkan jumlah data masing-masing kelas. Sementara itu, nilai *weighted average* sebesar 0,94 untuk *precision*, 0,94 untuk *recall*, dan 0,94 untuk *f1-score* menunjukkan bahwa model memiliki performa yang konsisten ketika mempertimbangkan proporsi jumlah data pada setiap kelas.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa model *NASNet Mobile* memiliki kemampuan klasifikasi yang sangat baik dalam mengenali jenis daun singkong. Tingginya nilai *accuracy*, *precision*, *recall*, dan *f1-score* menunjukkan bahwa model mampu membedakan karakteristik visual daun singkong karet, papua, dan sayur secara efektif. Meskipun masih terdapat beberapa kesalahan klasifikasi, terutama pada kelas daun singkong karet, jumlah kesalahan tersebut relatif kecil sehingga model dapat dikatakan memiliki kemampuan generalisasi yang baik terhadap data uji yang digunakan.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa arsitektur *NASNet Mobile* mampu memberikan performa yang baik dalam klasifikasi jenis daun singkong pada dataset yang tidak seimbang. Model berhasil mempelajari karakteristik visual daun singkong karet, papua, dan sayur secara efektif melalui proses preprocessing dan augmentasi citra, sehingga mampu menghasilkan klasifikasi yang akurat dan konsisten. Perolehan nilai akurasi sebesar 94% serta *weighted average precision*, *recall*, dan *F1-score* sebesar 0,94 menunjukkan bahwa *NASNet Mobile* memiliki kemampuan yang baik dalam menangani perbedaan distribusi data antar kelas tanpa mengalami penurunan performa yang signifikan.

Hasil penelitian ini menunjukkan bahwa penggunaan *NASNet Mobile* dapat menjadi solusi yang efektif untuk mendukung proses identifikasi jenis daun singkong secara otomatis, cepat, dan objektif dibandingkan metode identifikasi manual. Selain itu, penelitian ini memberikan kontribusi pada pengembangan penerapan deep learning di bidang pertanian, khususnya dalam pengenalan varietas tanaman berbasis citra digital. Dengan demikian, model yang dihasilkan berpotensi dikembangkan lebih lanjut sebagai sistem pendukung identifikasi tanaman yang dapat membantu meningkatkan efisiensi pengelolaan dan pemanfaatan komoditas singkong di sektor agrikultur.

DAFTAR PUSTAKA

- [1] A. D. Pamujiati, W. Artini, W. Andajani, and W. Widiyono, "Inovasi Diversifikasi Pangan Lokal melalui Pemanfaatan Daun Singkong menjadi Keripik sebagai Upaya Pengurangan Limbah dan Peningkatan Pendapatan Masyarakat," vol. 5, no. 2, pp. 144–155, 2025.
- [2] A. Broiler, "Review: potensi kulit singkong sebagai pakan ternak ayam broiler," vol. 4, no. 1, pp. 19–26, 2022.
- [3] F. A. Arafat, M. N. Ichsan, and M. F. Pramodya, "Pemanfaatan Arsitektur MOBILENET-CNN Untuk Mendiagnosis Penyakit Pada Daun Singkong Melalui Teknologi Citra Digital," vol. 4, pp. 73–78, 2025.
- [4] M. I. Rusdi *et al.*, "Pemberdayaan Kepada Masyarakat Melalui Kegiatan Pengolahan Daun Singkong Untuk Memanfaatkan Hasil Pertanian Sebagai Peningkatan Ekonomi Kreatif," vol. 2, no. 2, pp. 535–549, 2023.

- [5] L. Rakan, N. Aditya, and D. Putro, "Klasifikasi Penyakit Pada Tanaman Daun Singkong Menggunakan Vision Transformer," 2025.
- [6] J. T. Elektro, F. Teknik, and U. S. Karawang, "A robust MRI-based brain tumor classification via a hybrid deep learning technique," vol. 11, no. 1, pp. 276–282, 2022.
- [7] S. Adiningsi and R. A. Saputra, "Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model VGG16," *J. Inform. Polinema*, vol. 9, no. 4, pp. 451–460, 2023.
- [8] C. Neural, N. Cnn, and D. Arsitektur, "Klasifikasi Penyakit Daun Singkong Menggunakan Convolutional Neural Network (CNN) dengan Arsitektur VGG16 Berbasis Android," vol. 11, no. 1, pp. 53–59, 2025.
- [9] A. Fuadi and A. Suharso, "Perbandingan Arsitektur Mobilenet Dan Nasnetmobile Untuk Klasifikasi Penyakit Pada Citra Daun Kentang," *JIPi (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 7, no. 3, pp. 701–710, 2022, doi: 10.29100/jipi.v7i3.3026.
- [10] N. Hardi, "Komparasi Algoritma MobileNet Dan Nasnet Mobile Pada Klasifikasi Penyakit Daun Teh," *Reputasi J. Rekayasa Perangkat Lunak*, vol. 3, no. 1, pp. 50–55, 2022, doi: 10.31294/reputasi.v3i1.1313.
- [11] D. Kentang, "Perbandingan arsitektur mobilenet dan nasnetmobile untuk klasifikasi penyakit pada citra daun kentang," vol. 07, no. September, pp. 701–710, 2022.
- [12] T. P. Munthe, M. Akbar, F. T. Informasi, U. Mercu, and B. Yogyakarta, "Klasifikasi Citra Biji Kopi Temanggung Menggunakan Residual Network," vol. 5, no. 1, pp. 94–102, 2025.
- [13] D. T. Susetianingtias and E. Patriya, "Model Convolutional Neural Network (CNN) Custom Sequential untuk Klasifikasi Citra Ikan Hias Carassius Auratus pada Industri Akuakultur," vol. 5, no. 3, pp. 813–825, 2025.
- [14] U. Mahdiyah and R. Wulanningrum, "Identifikasi Penyakit Daun Tomat dengan Menggunakan NASNet Mobile," vol. 9, pp. 49–58.
- [15] S. E. Nassar, I. Yasser, H. M. Amer, and M. A. Mohamed, "A robust MRI-based brain tumor classification via a hybrid deep learning technique," *J. Supercomput.*, vol. 80, no. 2, pp. 2403–2427, 2024, doi: 10.1007/s11227-023-05549-w.