

Study Comparison MobileNetV2 dan MobileNetV3 untuk Klasifikasi Penyakit Daun Singkong Berbasis Citra

^{1*}Alfan Taufiqi Ramadhan, ²Rony Heri Irawan, ³Umi Mahdiyah

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

E-mail: ¹alfantaufigi66@gmail.com, ²rony@unpkediri.ac.id, ³umimahdiyah@gmail.com

Penulis Korespondens : Alfan Taufiqi Ramadhan

Abstrak— Penyakit pada daun singkong dapat menurunkan kualitas dan hasil panen sehingga diperlukan metode identifikasi yang cepat dan akurat. Penelitian ini bertujuan membandingkan kinerja arsitektur *MobileNetV2* dan *MobileNetV3-Small* dalam klasifikasi penyakit daun singkong berbasis citra. Dataset yang digunakan terdiri dari 5.000 citra yang dikelompokkan ke dalam lima kelas, yaitu sehat, mosaik, layu bakteri, bercak hijau, dan gumpal cokelat. Tahapan penelitian meliputi *preprocessing* citra, pelatihan model menggunakan *transfer learning*, serta evaluasi menggunakan *precision*, *recall*, dan *F1-score*. Hasil pelatihan menunjukkan bahwa *MobileNetV3-Small* memperoleh akurasi tertinggi sebesar 85,74%, sedangkan *MobileNetV2* memperoleh akurasi sebesar 83,45%. Namun, hasil evaluasi menunjukkan bahwa *MobileNetV2* memiliki performa yang lebih konsisten pada sebagian besar kelas berdasarkan nilai *F1-score*. Pada pengujian citra sampel, *MobileNetV2* juga menghasilkan *confidence* sebesar 95,69%, lebih tinggi dibandingkan *MobileNetV3-Small* sebesar 78,22%. Hasil penelitian menunjukkan bahwa kedua model mampu mengklasifikasikan penyakit daun singkong dengan baik, namun *MobileNetV2* memberikan performa yang lebih stabil pada data uji.

Kata Kunci— CNN, klasifikasi citra, *MobileNetV2*, *MobileNetV3-Small*, penyakit daun singkong.

Abstract— Cassava leaf diseases can reduce crop quality and yield, making fast and accurate identification methods essential. This study aims to compare the performance of *MobileNetV2* and *MobileNetV3-Small* architectures for image-based cassava leaf disease classification. The dataset consisted of 5,000 images divided into five classes: healthy, mosaic, bacterial wilt, green mite damage, and brown lump disease. The research stages included image preprocessing, model training using transfer learning, and evaluation using precision, recall, and F1-score metrics. The training results showed that *MobileNetV3-Small* achieved the highest accuracy of 85.74%, while *MobileNetV2* achieved 83.45%. However, the evaluation results indicated that *MobileNetV2* provided more consistent performance across most classes based on F1-score values. In sample image testing, *MobileNetV2* also produced a confidence score of 95.69%, higher than *MobileNetV3-Small* with 78.22%. The results demonstrate that both models are capable of classifying cassava leaf diseases effectively, with *MobileNetV2* showing more stable performance on the test data.

Keywords— cassava leaf disease, CNN, image classification, *MobileNetV2*, *MobileNetV3-Small*

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




I. PENDAHULUAN

Tanaman singkong (*Manihot esculenta*) merupakan salah satu komoditas penting di Indonesia yang berperan sebagai sumber pangan dan bahan baku industri. Namun, produktivitasnya sering mengalami penurunan akibat serangan penyakit daun seperti mosaik, layu bakteri, dan bercak daun yang dapat menurunkan kualitas serta hasil panen[1]. Proses identifikasi penyakit yang masih dilakukan secara manual cenderung tidak konsisten dan berpotensi menimbulkan kesalahan diagnosis[2]. Oleh karena itu, diperlukan metode otomatis yang mampu membantu proses identifikasi secara lebih akurat dan efisien[3]. Pemanfaatan *deep learning* dalam pengolahan citra mulai banyak digunakan untuk klasifikasi objek secara otomatis[4]. Salah satu metode yang umum digunakan adalah *Convolutional Neural Network* (CNN) karena mampu mengenali pola visual pada citra dengan baik. Penerapan CNN telah digunakan dalam berbagai penelitian dalam negeri, seperti klasifikasi motif batik dan deteksi citra *deepfake*, yang menunjukkan hasil cukup baik dalam mengenali pola kompleks [5]. Selain itu, CNN juga telah diterapkan pada klasifikasi penyakit daun singkong dan mampu menghasilkan tingkat akurasi yang tinggi dalam mengenali berbagai jenis penyakit berdasarkan citra daun, sehingga berpotensi membantu proses identifikasi penyakit secara lebih cepat dan akurat[6]. Perkembangan *Deep Learning*, khususnya *Convolutional Neural Network* (CNN), telah banyak dimanfaatkan untuk klasifikasi penyakit tanaman berbasis citra karena mampu menghasilkan tingkat akurasi yang tinggi[7]. Namun, model CNN konvensional umumnya memiliki kompleksitas dan kebutuhan komputasi yang besar sehingga kurang efisien untuk diterapkan pada perangkat dengan sumber daya terbatas[8]. Untuk mengatasi permasalahan tersebut, dikembangkan arsitektur ringan seperti *MobileNetV2* dan *MobileNetV3* yang mampu memberikan performa yang baik dengan kebutuhan komputasi yang lebih rendah[9]. *MobileNetV2* telah berhasil diterapkan pada klasifikasi penyakit daun singkong menggunakan metode *transfer learning* dengan hasil yang baik[10]. Meskipun demikian, penelitian yang membandingkan secara langsung performa *MobileNetV2* dan *MobileNetV3* pada klasifikasi penyakit daun singkong masih terbatas. Oleh karena itu, penelitian ini dilakukan untuk membandingkan kinerja kedua arsitektur tersebut dalam klasifikasi penyakit daun singkong berbasis citra.

II. METODE

Dalam penelitian ini, proses pengklasifikasian penyakit pada daun singkong dilaksanakan melalui serangkaian langkah yang diilustrasikan dalam Gambar 1 di bawah ini.



Gambar 1. Kerangka Kerja Penelitian

A. Pengumpulan Data

Data penelitian bersumber dari dataset publik *Kaggle* serta citra hasil akuisisi langsung di Kecamatan Patianrowo menggunakan kamera *smartphone*. Dataset yang digunakan terdiri dari lima kelas, yaitu sehat, mosaik, layu bakteri, bercak hijau, dan gumpal coklat, sebagaimana disajikan pada Tabel 1 dan Tabel 2.

Tabel 1. Pembagian Data

Jenis Daun	Jumlah Data	Data Latih	Data Validasi	Data Uji
Sehat	1000	800	200	100
Mosaik	1000	800	200	100
Layu Bakteri	1000	800	200	100
Bercak Hijau	1000	800	200	100
Gumpal Coklat	1000	800	200	100

Tabel 2. Contoh Dataset

Penyakit	Gambar
Sehat	
Mosaik	
Layu Bakteri	
Bercak Hijau	
Gumpal Coklat	

Data yang didapatkan kemudian dibagi menjadi dua yaitu data latih dan data uji, persentase pembagian 70% data latih, 15% data uji dan 15% data valid. Pembagian dataset dilakukan secara otomatis menggunakan *library* seperti *scikit-learn* dengan fungsi *train_test_split()* dan parameter *stratify*.

B. Preprocessing Data

Preprocessing dilakukan untuk meningkatkan kualitas data yang digunakan dalam penelitian. *Preprocessing* yang akan dilakukan adalah *resizing* data menjadi ukuran 224 x 224 piksel. Normalisasi nilai piksel untuk memastikan nilai berada dalam rentang tertentu. Augmentasi data dilakukan untuk memperluas variasi data yang digunakan seperti *rotation*, *flipping*, dan *cropping*.

C. Arsitektur Algoritma

MobileNetV2 merupakan pengembangan dari *MobileNetV1* yang memperkenalkan *inverted residual* dan *linear bottleneck* untuk meningkatkan efisiensi komputasi tanpa mengurangi performa model secara signifikan. Selanjutnya, *MobileNetV3* dikembangkan sebagai penyempurnaan dari *MobileNetV2* dengan mengombinasikan metode *Neural Architecture Search* (NAS) dan *NetAdapt* untuk menghasilkan arsitektur yang lebih optimal. *MobileNetV3* terdiri dari dua varian, yaitu *MobileNetV3-Large* dan *MobileNetV3-Small*, yang dirancang untuk kebutuhan komputasi tinggi dan rendah. Perbedaan utama *MobileNetV3* dibandingkan *MobileNetV2* terletak pada penggunaan modul *Squeeze-and-Excitation* (SE) dan aktivasi *Hard-Swish* yang mampu meningkatkan akurasi dengan tetap mempertahankan efisiensi model. Oleh karena itu, *MobileNetV2* dan *MobileNetV3* banyak digunakan pada tugas klasifikasi citra di perangkat dengan sumber

daya terbatas. Arsitektur *MobileNetV2* yang digunakan dalam penelitian ini ditunjukkan pada Tabel 3, sedangkan arsitektur *MobileNetV3-Small* ditunjukkan pada Tabel 4.

Tabel 3. Arsitektur *MobileNetV2*

Input	Operator	Exp Size	#Out	SE	NL	s
$224^2 \times 3$	Conv2d	-	32	-	ReLU6	2
$112^2 \times 32$	Bottleneck	32	16	-	ReLU6	1
$112^2 \times 16$	Bottleneck	96	24	-	ReLU6	2
$56^2 \times 24$	Bottleneck	144	32	-	ReLU6	2
$28^2 \times 32$	Bottleneck	192	64	-	ReLU6	2
$14^2 \times 64$	Bottleneck	384	96	-	ReLU6	1
$14^2 \times 96$	Bottleneck	576	160	-	ReLU	2
$7^2 \times 160$	Bottleneck	960	320	-	ReLU	1
$7^2 \times 320$	Conv2D 1×1	-	1280	-	ReLU	1
$7^2 \times 1280$	Average Pooling	-	-	-	-	-
$1^2 \times 1280$	Dense/Classifier	-	k	-	Softmax	-
$14^2 \times 80$	bneck, 3×3	480	112	✓	HS	1
$14^2 \times 112$	bneck, 3×3	672	112	✓	HS	1
$14^2 \times 112$	bneck, 5×5	672	160	✓	HS	2
$7^2 \times 160$	bneck, 5×5	960	160	✓	HS	1
$7^2 \times 160$	bneck, 5×5	960	160	✓	HS	1
$7^2 \times 160$	conv2d, 1×1	-	960	✓	HS	1
$7^2 \times 960$	pool, 7×7	-	-	-	-	-
$1^2 \times 960$	conv2d 1×1 , NBN	-	1280	-	HS	1
$1^2 \times 1280$	conv2d 1×1 , NBN	-	k	-	-	1

Tabel 4. Arsitektur MobileNetV3-Small

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d, 3×3	-	16	✓	HS	2
$112^2 \times 16$	bneck, 3×3	16	16	✓	RE	2
$56^2 \times 16$	bneck, 3×3	72	24	-	RE	2
$28^2 \times 24$	bneck, 3×3	88	24	-	RE	1
$28^2 \times 24$	bneck, 5×5	96	40	✓	HS	2
$14^2 \times 40$	bneck, 5×5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5×5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5×5	120	48	✓	HS	1
$14^2 \times 48$	bneck, 5×5	144	48	✓	HS	1
$14^2 \times 48$	bneck, 5×5	288	96	✓	HS	2
$7^2 \times 96$	bneck, 5×5	576	96	✓	HS	1
$7^2 \times 96$	bneck, 5×5	576	96	✓	HS	1
$7^2 \times 96$	conv2d, 1×1	-	576	✓	HS	1
$7^2 \times 576$	pool, 7×7	-	576	-	-	1
$1^2 \times 576$	conv2d 1×1, NBN	-	1280	-	HS	1
$1^2 \times 1280$	conv2d 1×1, NBN	-	k	-	-	1

D. Pelatihan Model

Pada tahap ini, dilakukan pelatihan model *MobileNetV2* dan *MobileNetV3* menggunakan dataset citra yang telah disiapkan sebelumnya. Masing-masing model dilatih melalui lima percobaan dengan variasi jumlah *epoch*. Hasil dari setiap percobaan kemudian dibandingkan untuk mengetahui pengaruh jumlah *epoch* terhadap performa kedua arsitektur. *Epoch* adalah satu siklus pelatihan yang terjadi ketika seluruh data latih telah diproses oleh model sebanyak satu kali.

E. Evaluasi

Proses evaluasi menggunakan *confusion matrix* untuk mengukur akurasi, presisi, *recall*, dan *F1-score*. Struktur *confusion matrix* yang digunakan dalam penelitian ini ditunjukkan pada Tabel 5. Matriks ini terdiri atas empat kemungkinan hasil klasifikasi, yaitu *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN), yang digunakan sebagai dasar dalam perhitungan metrik evaluasi model.:

Tabel 5. *Confusion Matrix*

	Predicted: Positive	Predicted: Negative
Actual: Positive	True Positive (TP)	False Negative (FN)
Actual: Negative	False Positive (FP)	True Negative (TN)

Penjelasan:

TP : Kasus yang sebenarnya positif dan diprediksi positif oleh model.

FN : Kasus yang sebenarnya positif tetapi diprediksi negatif oleh model.

FP : Kasus yang sebenarnya negatif tetapi diprediksi positif oleh model.

TN : Kasus yang sebenarnya negatif dan diprediksi negatif oleh model.

Berdasarkan nilai TP, FP, TN, dan FN yang diperoleh dari *confusion matrix*, dilakukan perhitungan beberapa metrik evaluasi. Nilai *accuracy* dihitung menggunakan Persamaan (1), *precision* dihitung menggunakan Persamaan (2), *recall* dihitung menggunakan Persamaan (3), dan *F1-score* dihitung menggunakan Persamaan (4). Keempat metrik tersebut digunakan untuk mengevaluasi performa model klasifikasi secara menyeluruh.:

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

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

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

$$F1 - Score = \frac{Precision \cdot Recall}{Precision + Recall} \quad (4)$$

III. HASIL DAN PEMBAHASAN

Berdasarkan hasil pengujian menggunakan 5.000 citra daun singkong yang dikelompokkan ke dalam lima kategori, yaitu sehat, mosaik, layu bakteri, bercak hijau, dan gumpal coklat, diperoleh perbedaan performa klasifikasi antara model MobileNetV2 dan MobileNetV3-Small. Hasil pelatihan kedua model pada variasi epoch yang berbeda ditunjukkan pada Tabel 6 dan Tabel 7, sedangkan hasil evaluasi model berdasarkan metrik precision, recall, dan F1-score untuk setiap kelas ditunjukkan pada Tabel 8 dan Tabel 9.

Tabel 6. Data Latih MobileNetV2

<i>Epoch</i>	<i>Accuracy</i>	<i>Loss</i>
10	0.7479	0.7293
20	0.7911	0.6292
30	0.8345	0.5166

Tabel 7. Data Latih MobileNetV3-Small

<i>Epoch</i>	<i>Accuracy</i>	<i>Loss</i>
10	0.7339	0.9260
20	0.7985	0.8261
30	0.8574	0.7171

Berdasarkan Tabel 6 dan Tabel 7, peningkatan jumlah *epoch* memberikan dampak positif terhadap performa *MobileNetV2* dan *MobileNetV3-Small*. Pada *epoch* ke-30, *MobileNetV2*

mencapai akurasi sebesar 0,8345 dengan *loss* 0,5166, sedangkan *MobileNetV3-Small* mencapai akurasi sebesar 0,8574 dengan *loss* 0,7171. Hasil tersebut menunjukkan bahwa *MobileNetV3-Small* memiliki tingkat akurasi yang lebih tinggi dibandingkan *MobileNetV2*, meskipun *MobileNetV2* menghasilkan nilai *loss* yang lebih rendah selama proses pelatihan. Dengan demikian, *MobileNetV3-Small* menunjukkan kemampuan yang lebih baik dalam mengenali pola pada data latih yang digunakan.

Tabel 8. Evaluasi *MobileNetV2*

	Precision	Recall	F1-Score
Bercak Hijau	0.88	0.57	0.69
Gumpal Coklat	0.80	0.62	0.70
Layu	0.66	0.72	0.69
Mosaik	0.83	0.83	0.83
Sehat	0.51	0.75	0.60

Tabel 9. Evaluasi *MobileNetV3-Small*

	Precision	Recall	F1-Score
Bercak Hijau	0.89	0.59	0.71
Gumpal Coklat	0.66	0.69	0.68
Layu	0.60	0.69	0.65
Mosaik	0.83	0.75	0.80
Sehat	0.56	0.66	0.60

Berdasarkan Tabel 8 dan Tabel 9, *MobileNetV2* dan *MobileNetV3-Small* mampu mengklasifikasikan lima kategori penyakit daun singkong dengan baik. *MobileNetV2* menghasilkan nilai *F1-score* yang lebih tinggi pada kelas gumpal coklat, layu, dan mosaik, sedangkan *MobileNetV3-Small* unggul pada kelas bercak hijau. Kedua model memperoleh performa terbaik pada kelas mosaik, dengan *F1-score* sebesar 0,83 untuk *MobileNetV2* dan 0,80 untuk *MobileNetV3-Small*. Secara keseluruhan, *MobileNetV2* menunjukkan performa yang lebih

konsisten dibandingkan *MobileNetV3-Small* berdasarkan nilai *precision*, *recall*, dan *F1-score* pada sebagian besar kelas.

MobileNetV3
Prediksi: Bercak
Confidence: 78.22%



Gambar 2. Hasil Prediksi MobileNetV3

MobileNetV2
Prediksi: Bercak
Confidence: 95.69%



Gambar 3. Hasil Prediksi MobileNetV2

Gambar 2 menunjukkan hasil prediksi citra uji daun singkong kelas bercak hijau menggunakan MobileNetV3-Small, sedangkan Gambar 3 menunjukkan hasil prediksi menggunakan MobileNetV2. Berdasarkan kedua gambar tersebut, kedua model berhasil mengklasifikasikan citra ke dalam kelas Bercak. Namun, MobileNetV2 menghasilkan nilai confidence yang lebih tinggi, yaitu 95,69%, dibandingkan MobileNetV3-Small yang memperoleh 78,22%. Hasil ini

menunjukkan bahwa MobileNetV2 memiliki tingkat keyakinan yang lebih baik dalam mengenali pola visual penyakit bercak hijau pada citra uji.

IV. KESIMPULAN

Penelitian ini berhasil membandingkan performa *MobileNetV2* dan *MobileNetV3-Small* dalam klasifikasi penyakit daun singkong berbasis citra. Hasil pelatihan menunjukkan bahwa *MobileNetV3-Small* memperoleh akurasi yang lebih tinggi dibandingkan *MobileNetV2*, yaitu sebesar 85,74% dan 83,45%. Namun, berdasarkan hasil evaluasi menggunakan *precision*, *recall*, dan *F1-score*, *MobileNetV2* menunjukkan performa yang lebih konsisten pada sebagian besar kelas penyakit. Selain itu, pada pengujian citra sampel, *MobileNetV2* menghasilkan nilai *confidence* yang lebih tinggi dibandingkan *MobileNetV3-Small*. Dengan demikian, meskipun *MobileNetV3-Small* memiliki akurasi pelatihan yang lebih tinggi, *MobileNetV2* menunjukkan kemampuan klasifikasi yang lebih stabil dan dapat menjadi pilihan yang lebih baik untuk klasifikasi penyakit daun singkong berbasis citra.

DAFTAR PUSTAKA

- [1] D. Lizard, S. Dimara, B. Rahmat, and H. Maulana, "IDENTIFIKASI PENYAKIT DAUN PADI DENGAN METODE TRANSFER LEARNING MOBILENET-SUPPORT VECTOR MACHINE," 2025.
- [2] M. Patrick, C. Lubis, and A. B. Dharmawan, "PENDETEKSIAN CITRA DEEPFAKE WAJAH DI SMARTPHONE MENGGUNAKAN MOBILENETV3-SMALL DAN LBP," *Jurnal Ilmu Komputer dan Sistem Informasi*, vol. 12, Jan. 2024, doi: 10.24912/jiksi.v12i1.28214.
- [3] A. A. Aldi and T. Tinaliah, "Classification of Indonesian Batik Patterns Using Convolutional Neural Network with MobileNetV3 Architecture," *Jurnal Teknologi Informatika dan Komputer*, vol. 12, pp. 38–53, Dec. 2025, doi: 10.37012/jtik.v12i1.3205.
- [4] A. Kurniadi, "Implementasi Convolutional Neural Network Untuk Klasifikasi Varietas Pada Citra Daun Sawi Menggunakan Keras," *DoubleClick: Journal of Computer and Information Technology*, vol. 4, p. 25, Aug. 2020, doi: 10.25273/doubleclick.v4i1.5812.
- [5] P. K. Das, S. S. Rupa, S. Pumrin, U. C. Das, and M. K. Hossen, "Deep Learning for Plant Disease Detection and Classification: A Systematic Analysis and Review," May 2024, *King Mongkut's Institute of Technology Ladkrabang*. doi: 10.55003/cast.2024.259016.
- [6] A. M. Anggraeni, T. I. Hermanto, and I. M. Nugroho, "KLASIFIKASI PENYAKIT DAUN SINGKONG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN ARSITEKTUR VGG16 BERBASIS ANDROID," 2025, Accessed: Jun. 17, 2026. [Online]. Available: <https://journal.nurulfikri.ac.id/index.php/jtt>
- [7] A. Emmanuel, R. W. Mwangi, P. Murithi, K. Fredrick, and T. Danison, "Classification of cassava leaf diseases using deep Gaussian transfer learning model," *Engineering Reports*, vol. 5, Sep. 2023, doi: 10.1002/eng2.12651.
- [8] S. Agustiani, R. Aryanti, S. Khotimatul Wildah, Y. T. Arifin, S. Marlina, and T. Misriati, "Optimisasi Model Deep Learning untuk Deteksi Penyakit Daun Tebu dengan Fine-Tuning MobileNetV2," *Journal of Informatics Management and Information Technology*, vol. 4, no. 4, pp. 150–157, 2024, doi: 10.47065/jimat.v4i4.411.
- [9] E. L. Puji Ristanti, "ANALISIS DAN PERBANDINGAN ARSITEKTUR VGG16 DAN MOBILENETV2 UNTUK KLASIFIKASI DAN IDENTIFIKASI PENYAKIT DAUN PADA TANAMAN CABAI MENGGUNAKAN CNN," <https://jurnal.kolibi.org/index.php/scientica/article/view/2381/2303>.
- [10] M. F. Aulia, M. K. Gibran, N. S. A. Sitorus, A. Nugroho, N. Faiza, and H. A. R. Siregar, "Transfer Learning Implementation with MobileNetV2 for Cassava Leaf Disease Detection," *JURNAL TEKNOLOGI DAN OPEN SOURCE*, vol. 8, pp. 352–361, Jun. 2025, doi: 10.36378/jtos.v8i1.4442.