

Implementasi Fine-Tuning MobileNetV2 untuk Klasifikasi Sampah Organik dan Anorganik Berbasis Android

^{1*}Mohammad Ubaidillah Ridlo, ²Resty Wulanningrum, ³Risky Aswi
Ramadhani

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

E-mail: ¹ubaidillahridlo57@gmail.com, ²restyw@unpkdr.ac.id, ³riskyaswiramadhani@gmail.com

Penulis Korespondensi : Mohammad Ubaidillah Ridlo

Abstrak—Proses pemilahan sampah yang masih dilakukan secara manual sering menyebabkan pengelolaan sampah menjadi kurang efektif dan membutuhkan waktu yang relatif lama. Kondisi tersebut mendorong pemanfaatan teknologi berbasis *Artificial Intelligence* untuk membantu proses klasifikasi sampah secara otomatis. Penelitian ini mengembangkan sistem klasifikasi sampah organik dan anorganik berbasis Android menggunakan arsitektur MobileNetV2 dengan pendekatan *fine-tuning*. Dataset penelitian terdiri dari 400 citra yang diperoleh menggunakan kamera *smartphone* pada berbagai kondisi lingkungan dan pencahayaan. Tahapan penelitian meliputi *preprocessing* citra, pelatihan model menggunakan *transfer learning*, konversi model TensorFlow Lite, serta implementasi pada perangkat Android. Berdasarkan hasil pengujian, sistem mampu melakukan klasifikasi secara *real-time* dengan *confidence score* yang stabil pada rentang 91% hingga 94%. Implementasi MobileNetV2 menunjukkan bahwa model *lightweight* dapat digunakan untuk mendukung sistem klasifikasi sampah berbasis *mobile* dengan kebutuhan komputasi yang efisien.

Kata Kunci—Android, Fine-Tuning, Klasifikasi Sampah, MobileNetV2, TensorFlow Lite

Abstract—Manual waste sorting processes often make waste management less effective and require a relatively long processing time. This condition encourages the utilization of Artificial Intelligence technology to support automatic waste classification systems. This study develops an Android-based organic and inorganic waste classification system using the MobileNetV2 architecture with a fine-tuning approach. The dataset consisted of 400 images collected using a smartphone camera under various environmental and lighting conditions. The research stages included image preprocessing, transfer learning-based model training, TensorFlow Lite model conversion, and implementation on Android devices. Based on the testing results, the system was able to perform real-time classification with stable confidence scores ranging from 91% to 94%. The implementation of MobileNetV2 demonstrates that a lightweight model can support mobile-based waste classification systems with efficient computational requirements.

Keywords—Android, Fine-Tuning, MobileNetV2, TensorFlow Lite, Waste Classification

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



I. PENDAHULUAN

Peningkatan volume sampah akibat aktivitas manusia menjadi salah satu permasalahan lingkungan yang terus berkembang, khususnya di negara berkembang seperti Indonesia [1]. Proses pemilahan sampah yang kurang optimal dapat menyebabkan pencemaran lingkungan dan menurunkan efektivitas proses pengelolaan limbah [2]. Sampah secara umum dibedakan menjadi

dua kategori utama, yaitu sampah organik yang mudah terurai secara alami dan sampah anorganik yang memerlukan proses pengolahan khusus. Kesalahan pada proses pemilahan sampah dapat menyebabkan pengelolaan sampah menjadi tidak efisien serta meningkatkan penumpukan limbah pada tempat pembuangan akhir. Pada praktiknya, proses pemilahan sampah masih banyak dilakukan secara manual menggunakan tenaga manusia [3]. Metode tersebut memiliki beberapa kelemahan, seperti membutuhkan waktu yang relatif lama, rentan terhadap kesalahan klasifikasi, dan kurang efektif ketika digunakan untuk menangani volume sampah dalam jumlah besar. Selain itu, perbedaan bentuk, warna, dan kondisi objek sampah sering menyebabkan proses identifikasi menjadi tidak konsisten. Oleh karena itu, dibutuhkan sistem otomatis yang mampu melakukan klasifikasi sampah secara cepat dan efisien.

Perkembangan *Artificial Intelligence* pada bidang *Computer Vision* memungkinkan pengembangan sistem klasifikasi objek berbasis citra digital [4]. Salah satu metode yang banyak digunakan pada klasifikasi citra adalah *Convolutional Neural Network* (CNN) karena mampu mengenali pola visual objek dengan baik [5]. Implementasi CNN pada perangkat *mobile* juga mulai banyak dikembangkan untuk mendukung proses klasifikasi secara *real-time* pada lingkungan nyata. Beberapa penelitian sebelumnya telah menerapkan metode *deep learning* untuk klasifikasi sampah berbasis citra digital [6], [7], [8], [9]. Namun, sebagian besar penelitian masih menggunakan model dengan kebutuhan komputasi yang cukup besar sehingga kurang optimal untuk implementasi pada perangkat *mobile* [10]. Selain itu, penggunaan dataset dengan kondisi visual yang terlalu terkontrol menyebabkan model kurang adaptif terhadap variasi pencahayaan, sudut pengambilan gambar, dan latar belakang objek pada penggunaan nyata.

MobileNetV2 merupakan salah satu arsitektur *lightweight* yang dirancang untuk perangkat dengan keterbatasan sumber daya komputasi. Arsitektur ini memiliki ukuran model yang relatif ringan sehingga lebih sesuai untuk implementasi sistem klasifikasi berbasis Android secara *real-time*. Selain itu, penggunaan TensorFlow Lite memungkinkan proses inferensi model dapat berjalan lebih efisien pada perangkat *mobile*. Berdasarkan permasalahan tersebut, penelitian ini mengimplementasikan MobileNetV2 dengan pendekatan *fine-tuning* untuk klasifikasi sampah organik dan anorganik berbasis Android. Penelitian ini diharapkan dapat menghasilkan sistem klasifikasi sampah yang mampu melakukan proses identifikasi secara *real-time* dengan kebutuhan komputasi yang ringan dan performa klasifikasi yang baik.

II. METODE

Penelitian ini dilakukan melalui beberapa tahapan utama yang meliputi pengumpulan dataset, *preprocessing* data, pembagian dataset, pelatihan model, pengujian model, dan evaluasi performa. Alur penelitian digunakan untuk mengimplementasikan MobileNetV2 dengan pendekatan *fine-tuning* pada klasifikasi sampah organik dan anorganik berbasis Android.



Gambar 1. Diagram Alur Penelitian

Dataset yang digunakan merupakan dataset primer yang dikumpulkan secara mandiri menggunakan kamera *smartphone* [11]. Dataset terdiri dari dua kategori utama, yaitu sampah organik dan sampah anorganik. Proses pengambilan citra dilakukan dengan variasi pencahayaan, sudut pengambilan gambar, latar belakang, dan bentuk objek untuk meningkatkan keragaman visual dataset. Total dataset yang digunakan sebanyak 400 citra.

Sebelum digunakan pada proses pelatihan, seluruh citra dilakukan tahap *preprocessing* berupa *resize* menjadi 224×224 piksel sesuai ukuran *input* standar MobileNetV2 [12]. Selain itu, dilakukan normalisasi nilai piksel untuk mempercepat proses pelatihan model [13]. Dataset kemudian dibagi menjadi data pelatihan, validasi, dan pengujian menggunakan rasio 70:20:10 [14]. Distribusi dataset penelitian ditunjukkan pada Tabel 1.

Tabel 1. Distribusi dataset penelitian

Jenis Data	Jumlah
Data Pelatihan	280
Data Validasi	80
Data Pengujian	40

Penelitian ini menggunakan arsitektur MobileNetV2 sebagai model utama klasifikasi sampah. MobileNetV2 dipilih karena memiliki kompleksitas parameter yang lebih rendah dibandingkan arsitektur CNN konvensional sehingga lebih efisien untuk implementasi pada perangkat *mobile* [15]. Model menggunakan bobot *pretrained* ImageNet untuk memanfaatkan kemampuan *transfer learning* dalam mengekstraksi fitur visual dasar sebelum dilakukan proses *fine-tuning* pada beberapa *layer* akhir model [16].

Proses pelatihan model dilakukan menggunakan *framework* TensorFlow dan Keras dengan *optimizer* Adam [17]. Fungsi aktivasi pada *layer output* menggunakan Softmax karena penelitian

menggunakan klasifikasi dua kelas. Selain itu, digunakan *callback Early Stopping* untuk mengurangi risiko *overfitting* pada dataset terbatas [18]. Setelah proses pelatihan selesai, model kemudian dikonversi ke format TensorFlow Lite agar dapat diimplementasikan pada perangkat Android dengan kebutuhan komputasi yang lebih ringan [19].

Tabel 2. Parameter Pelatihan Model

Parameter	Nilai
Input Size	224×224
Optimizer	Adam
Batch Size	16
Epoch	10
Learning Rate	0.0001
Early Stopping	Patience = 3

Pelatihan model dilakukan menggunakan parameter yang ditunjukkan pada Tabel 2. Pengaturan parameter tersebut digunakan untuk memperoleh proses konvergensi yang stabil serta mengurangi risiko *overfitting* pada dataset yang relatif terbatas.

Evaluasi performa klasifikasi dilakukan menggunakan *accuracy*, *precision*, *recall*, dan *F1-score* [20]. Persamaan *accuracy* ditunjukkan pada Persamaan (1).

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

Persamaan *precision* ditunjukkan pada Persamaan (2).

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

Persamaan *recall* ditunjukkan pada Persamaan (3).

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

Persamaan *F1-score* ditunjukkan pada Persamaan (4).

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$


Keterangan:

- a. TP (*True Positive*)
- b. TN (*True Negative*)
- c. FP (*False Positive*)
- d. FN (*False Negative*)

Model hasil pelatihan kemudian diimplementasikan pada perangkat Android menggunakan TensorFlow Lite untuk melakukan klasifikasi sampah secara real-time melalui kamera smartphone. Sistem Android dirancang untuk menampilkan hasil klasifikasi beserta confidence score pada antarmuka aplikasi.

III. HASIL DAN PEMBAHASAN

Proses pelatihan model dilakukan menggunakan arsitektur MobileNetV2 dengan pendekatan *fine-tuning* pada beberapa *layer* akhir model. Pelatihan dilakukan menggunakan dataset primer yang terdiri dari dua kategori utama, yaitu sampah organik dan sampah anorganik. Selama proses pelatihan, model menunjukkan peningkatan performa secara bertahap pada data pelatihan dan validasi. Grafik hasil pelatihan model ditunjukkan pada Gambar 2.



Gambar 2. Grafik Accuracy dan Loss Proses Pelatihan Model

Berdasarkan hasil pelatihan, model mampu mencapai performa klasifikasi yang stabil dengan nilai *accuracy* dan *loss* yang menunjukkan proses konvergensi yang baik. Penggunaan pendekatan *fine-tuning* pada MobileNetV2 membantu model dalam mengenali karakteristik visual objek sampah pada dataset primer yang memiliki variasi pencahayaan, sudut pengambilan gambar, dan latar belakang objek. Selain itu, penggunaan *callback Early Stopping* membantu mengurangi risiko *overfitting* selama proses pelatihan model.

Evaluasi performa klasifikasi dilakukan menggunakan *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil evaluasi performa model ditunjukkan pada Tabel 3.

Tabel 3. Hasil Evaluasi Performa Model

Metrik	Nilai
Accuracy	1.000
Precision	1.000
Recall	1.000
F1-Score	1.000

Berdasarkan hasil evaluasi pada Tabel 3, model MobileNetV2 menunjukkan performa klasifikasi yang sangat baik pada dataset pengujian. Nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang tinggi menunjukkan bahwa model mampu mengenali kategori sampah organik dan anorganik dengan tingkat klasifikasi yang konsisten. Hasil tersebut menunjukkan bahwa pendekatan *fine-tuning* dapat membantu meningkatkan kemampuan model dalam menyesuaikan karakteristik visual dataset primer.

Model hasil pelatihan kemudian dikonversi ke format TensorFlow Lite dan diimplementasikan pada perangkat Android untuk melakukan klasifikasi sampah secara *real-time*. Pengujian implementasi dilakukan menggunakan kamera *smartphone* pada berbagai kondisi lingkungan dan pencahayaan. Sistem Android mampu menampilkan hasil klasifikasi beserta *confidence score*

secara langsung pada antarmuka aplikasi. Implementasi sistem klasifikasi sampah berbasis Android ditunjukkan pada Gambar 3.



Gambar 3. Implementasi sistem klasifikasi sampah pada perangkat Android

Berdasarkan hasil pengujian secara langsung pada perangkat Android, sistem mampu melakukan proses klasifikasi secara *real-time* dengan *confidence score* pada rentang 91% hingga 94%. Penggunaan MobileNetV2 memberikan performa inferensi yang cukup ringan sehingga proses klasifikasi dapat berjalan dengan respons yang stabil pada perangkat *mobile*. Selain itu, implementasi TensorFlow Lite membantu mengurangi kebutuhan komputasi model sehingga sistem dapat digunakan dengan lebih efisien pada *smartphone* Android.

Hasil penelitian menunjukkan bahwa implementasi MobileNetV2 dengan pendekatan *fine-tuning* memiliki potensi yang baik untuk diterapkan pada sistem klasifikasi sampah berbasis Android. Kombinasi arsitektur *lightweight* dan implementasi TensorFlow Lite memungkinkan sistem melakukan klasifikasi citra secara cepat dengan performa yang stabil pada perangkat *mobile*. Selain itu, penggunaan dataset primer dengan variasi kondisi lingkungan membantu model dalam beradaptasi terhadap penggunaan pada kondisi nyata.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, implementasi MobileNetV2 dengan pendekatan *fine-tuning* berhasil diterapkan pada sistem klasifikasi sampah organik dan anorganik

berbasis Android. Model mampu melakukan proses klasifikasi dengan performa yang baik pada dataset primer yang memiliki variasi pencahayaan, sudut pengambilan gambar, dan latar belakang objek.

Hasil pengujian menunjukkan bahwa model memiliki performa klasifikasi yang baik berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, implementasi TensorFlow Lite memungkinkan sistem melakukan proses klasifikasi secara *real-time* pada perangkat Android dengan kebutuhan komputasi yang relatif ringan. Berdasarkan hasil pengujian secara langsung, sistem mampu menampilkan hasil klasifikasi dengan *confidence score* yang stabil pada berbagai kondisi lingkungan.

Penelitian ini menunjukkan bahwa kombinasi MobileNetV2 dan *fine-tuning* memiliki potensi yang baik untuk diterapkan pada sistem klasifikasi sampah berbasis *mobile*. Pengembangan selanjutnya dapat dilakukan dengan menambahkan jumlah dataset dan kategori sampah yang lebih beragam untuk meningkatkan kemampuan generalisasi model.

DAFTAR PUSTAKA

- [1] M. Farhan Aditiya, D. I. Shafa, and A. H. Lubis, "Analisis Kinerja Convolutional Neural Network dalam Mengklasifikasikan Sampah Rumah Tangga," *REMIK: Riset dan E-Jurnal Manajemen Informatika Komputer*, vol. 10, no. 2, pp. 553–561, Apr. 2026, doi: 10.33395/REMIK.V10I2.16078.
- [2] M. E. Purba, A. Z. Situmorang, G. L. B. Ginting, M. W. P. Lubis, and F. M. Sinaga, "Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN," *Jurnal Sifo Mikroskil*, vol. 26, no. 1, pp. 37–54, Apr. 2025, doi: 10.55601/JS.M.V26I1.1510.
- [3] A. I. Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 1, pp. 142–149–142 – 149, Apr. 2022, doi: 10.28932/JUTISI.V8I1.4314.
- [4] L. Rahmawati, S. Defianti, and U. S. Karawang, "Klasifikasi Jenis Sampah Menggunakan Convolutional Neural Network untuk Mendukung Pengelolaan Limbah," *Jurnal Janitra Informatika dan Sistem Informasi*, vol. 6, no. 1, pp. 61–68, Apr. 2026, doi: 10.59395/EXAXYJ37.
- [5] Z. I. Nugraha, Arnita, K. S. S. A. Setiawan, R. Maharani, and F. Zaharani, "Implementasi Algoritma CNN dalam Pengembangan Website untuk Klasifikasi Sampah Organik, dan Non-Organik," *Jurnal Manajemen Informatika dan Sistem Informasi*, vol. 8, no. 1, pp. 90–101, Jan. 2025, doi: 10.36595/MISI.V8I1.1355.
- [6] V. Ayumi, "Deep Learning-Based Multi-Class Waste Classification Using the VGG16 Model," *JSAI (Journal Scientific and Applied Informatics)*, vol. 9, no. 1, pp. 126–131, Jan. 2026, doi: 10.36085/JSAI.V9I1.9880.
- [7] A. M. Simarmata, P. Salim, N. J. Waruwu, and J. Jessica, "Densenet Architecture Implementation for Organic and Non-Organic Waste," *Sinkron : jurnal dan penelitian teknik informatika*, vol. 7, no. 4, pp. 2444–2449, Oct. 2023, doi: 10.33395/SINKRON.V8I4.12765.
- [8] M. Rahina, B. Pambayun, and Y. Azhar, "Implementasi Data Augmentation untuk Klasifikasi Sampah Organik dan Non Organik Menggunakan Inception-V3," *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 9, no. 3, pp. 192–204, Sep. 2024, doi: 10.14421/jiska.2024.9.3.192-204.

- [9] A. Ikhlas and B. Hendrik, "Literature Review: A Comparative Study of Waste Classification using Deep Learning Algorithms," *Sistemasi: Jurnal Sistem Informasi*, vol. 14, no. 3, pp. 1360–1369, May 2025, doi: 10.32520/STMSI.V14I3.5163.
- [10] A. D. Pritama, V. S. Kusuma, W. M. Baihaqi, and P. Subarkah, "Enhancing Waste Classification with MobileNetV2: Adding a Plastic Sachets Class for Sustainable Management," *Edu Komputika Journal*, vol. 12, no. 1, pp. 13–20, Aug. 2025, doi: 10.15294/EDUKOM.V12I1.18931.
- [11] D. I. S. H. Julu and D. Nurdiah, "Klasifikasi Sampah Organik dan Non Organik Menggunakan Transfer Learning," *Jurnal Transformatika*, vol. 23, no. 1, pp. 12–29, Jul. 2025, doi: 10.26623/TRANSFORMATIKA.V23I1.12201.
- [12] S. E. Thio and J. Susilo, "Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0," *bit-Tech*, vol. 8, no. 1, pp. 25–32, Aug. 2025, doi: 10.32877/BT.V8I1.1900.
- [13] N. Farros *et al.*, "Perbandingan Akurasi dan Performa MobileNetV2 dan EfficientNetV2 Untuk Klasifikasi Sampah," *JUSTIN (Jurnal Sistem dan Teknologi Informasi)*, vol. 14, no. 1, pp. 16–22, Jan. 2026, doi: 10.26418/JUSTIN.V14I1.89086.
- [14] D. Y. Prakosa, R. Oktavian, and A. P. Kardana, "Klasifikasi Citra Sampah Daur Ulang Menggunakan Arsitektur MobileNetV2 dengan Strategi Fine-Tuning," *Journal of Information System and Application Development*, vol. 4, no. 1, pp. 169–174, Mar. 2026, doi: 10.26905/JISAD.V4I1.16740.
- [15] A. Marzuki, A. Zaky, B. Handoko, D. Q. Mustieni, and N. Risyadi, "IoT-Based Reverse Vending Machine with Deep Learning for Bottle Waste Management," *bit-Tech*, vol. 8, no. 2, pp. 1995–2003, Dec. 2025, doi: 10.32877/BT.V8I2.3183.
- [16] A. Asmawati, Y. Kurniawan, and R. N. Fadilah, "Efisiensi Pemilahan Sampah Daur Ulang Menggunakan Model CNN SSD MobileNet V2," *ICIT Journal*, vol. 11, no. 2, pp. 197–208, Aug. 2025, doi: 10.33050/ICIT.V11I2.3939.
- [17] E. Rumayar, Q. C. Kainde, and K. Santa, "Aplikasi Pendeteksi dan Pengklasifikasi Sampah Berbasis Android Menggunakan Algoritma SSD MobileNetV2," *TIN: Terapan Informatika Nusantara*, vol. 6, no. 5, pp. 554–566, Oct. 2025, doi: 10.47065/TIN.V6I5.8453.
- [18] D. A. Rismayadi and M. A. Muharam, "Pemanfaatan Machine Learning untuk Optimalisasi Limbah dengan Model MOBILENETV2 pada Aplikasi Android," *Naratif J. Nas. Riset, Apl. dan Tek. Inform.*, vol. 6, no. 1, pp. 72–78, Jul. 2024, doi: 10.53580/NARATIF.V6I1.289.
- [19] R. Albana and H. Siregar, "Rancang Bangun Aplikasi Edukasi Pemilahan Sampah 'Pilahn' Berbasis Android Menggunakan Kotlin," *Jurnal Komputer Teknologi Informasi Sistem Komputer (JUKTISI)*, vol. 4, no. 3, pp. 2038–2048, Jan. 2026, doi: 10.62712/JUKTISI.V4I3.792.
- [20] A. Toyib, N. Wahid, F. Khozy Affifudin, M. Aditya, and D. Muriyatmoko, "Implementasi Arsitektur MobileNetV2 untuk Klasifikasi Sampah Organik dan Anorganik Berbasis Android," *Seminar Nasional Teknologi & Sains*, vol. 5, no. 1, pp. 907–913, Jan. 2026, doi: 10.29407/HBY4ZX45.