

Klasifikasi Citra Sampah Daur Ulang Menggunakan Arsitektur MobileNetV2 dengan Strategi Fine-Tuning

*Recyclable Waste Classification Using Transfer Learning-Based MobileNetV2
Architecture*

Danang Yudo Prakoso*, Reno Oktavian, Agio Prima
Universitas Amikom Yogyakarta

E-mail: *danangyp@students.amikom.ac.id,

Abstract. Waste management is a critical global issue where automated sorting is key to recycling efficiency. This study aims to build an automated waste classification model capable of recognizing five main categories: cardboard, metal, paper, plastic, and residual trash. The proposed approach uses Transfer Learning on the MobileNetV2 Convolutional Neural Network (CNN) architecture, known for its computational efficiency. To address dataset imbalance, this study applies Class Weighting techniques and a gradual Fine-Tuning strategy on the base model layers. The model was trained using a dataset consisting of 4,272 training images and 2,026 validation images. Test results show that the model achieved an accuracy of 90.23% on validation data. In-depth evaluation using a Confusion Matrix revealed very high performance for metal (recall 1.00) and paper (recall 0.96) classes, but significant challenges in the residual trash class. These results indicate that while MobileNetV2 is highly effective for recognizing recyclable materials with distinct shape features, extreme visual variations in the residual class require further specific handling.

Keywords: Waste Classification, Deep Learning, MobileNetV2, Transfer Learning, Computer Vision.

Abstrak. Permasalahan pengelolaan sampah menjadi isu global yang krusial, di mana pemilahan otomatis menjadi kunci efisiensi daur ulang. Penelitian ini bertujuan untuk membangun model klasifikasi sampah otomatis yang mampu mengenali lima kategori utama: kardus, logam, kertas, plastik, dan sampah residu (trash). Pendekatan yang diusulkan menggunakan *Transfer Learning* pada arsitektur *Convolutional Neural Network (CNN) MobileNetV2* yang dikenal efisien secara komputasi. Untuk mengatasi ketidakseimbangan data (imbalance dataset), penelitian ini menerapkan teknik *Class Weighting* serta strategi *Fine-Tuning* bertahap pada lapisan base model. Model dilatih menggunakan dataset yang terdiri dari 4.272 data latih dan 2.026 data validasi. Hasil pengujian menunjukkan bahwa model mencapai akurasi sebesar 90,23% pada data validasi. Evaluasi mendalam menggunakan *Confusion Matrix* menunjukkan performa sangat tinggi pada kelas logam (recall 1.00) dan kertas (recall 0.96), namun menemukan tantangan signifikan pada kelas sampah residu. Hasil ini mengindikasikan bahwa meskipun *MobileNetV2* sangat efektif untuk mengenali material daur ulang yang memiliki fitur bentuk tegas, variasi visual yang ekstrem pada kelas residu memerlukan penanganan khusus lebih lanjut.

Kata kunci: *Deep Learning, Klasifikasi Sampah, MobileNetV2, Transfer Learning, Imbalance Data.*

Submitted: 04-02-2026 | Accepted: 25-03-2026 | Published: 31-03-2026

How to Cite:

D. Y. Prakoso, R. Oktavian and A. Prima, Klasifikasi Citra Sampah Daur Ulang Menggunakan Arsitektur MobileNetV2 dengan Strategi Fine-Tuning" *Journal of Information System and Application Development (JISAD)*, vol. 4, no. 1, pp. 169-174, 2026, doi: 10.26905/jisad.v4i1.16740.



PENDAHULUAN

Pengelolaan limbah padat yang efektif merupakan salah satu tantangan lingkungan terbesar secara global. Peningkatan volume sampah, terutama jenis anorganik yang sulit terurai, menuntut adanya sistem pemilahan yang cepat dan akurat untuk mendukung proses daur ulang. Metode pemilahan manual yang masih dominan saat ini dinilai tidak efisien, memakan waktu lama, serta berisiko terhadap kesehatan pekerja [1]. Oleh karena itu, penerapan kecerdasan buatan, khususnya *Deep Learning* dengan algoritma *Convolutional Neural Network* (CNN), telah menjadi standar baru dalam otomatisasi klasifikasi citra sampah karena kemampuannya mengekstraksi fitur visual yang kompleks secara otomatis [2].

Meskipun CNN terbukti andal, tantangan utama dalam implementasi sistem pemilahan sampah cerdas (*smart waste management*) adalah kebutuhan sumber daya komputasi yang besar. Arsitektur CNN konvensional seperti VGG16 atau ResNet seringkali memiliki jumlah parameter yang sangat banyak, sehingga sulit diterapkan pada perangkat keras terbatas, seperti *embedded system* pada tempat sampah pintar [3]. Penelitian terbaru [4] menunjukkan bahwa meskipun model seperti VGG16 memiliki akurasi yang baik, arsitektur *lightweight* seperti *MobileNetV2* menawarkan efisiensi komputasi yang jauh lebih tinggi dengan penurunan akurasi yang sangat minimal, menjadikannya kandidat ideal untuk aplikasi *real-time*.

Selain masalah komputasi, kendala signifikan yang sering diabaikan dalam penelitian klasifikasi sampah adalah ketidakseimbangan dataset (*imbalanced dataset*). Sebagian besar dataset publik memiliki distribusi kelas yang tidak merata, yang menyebabkan model cenderung bias ke kelas mayoritas dan gagal mengenali kelas minoritas dengan baik [5]. Peninjauan sistematis menyoroti ketidakseimbangan data dan variabilitas dunia nyata merupakan hambatan utama yang menurunkan reliabilitas sistem klasifikasi otomatis.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan model klasifikasi sampah yang tidak hanya akurat tetapi juga efisien secara komputasi. Penelitian ini mengusulkan penggunaan teknik *Transfer Learning* pada arsitektur *MobileNetV2* untuk mengatasi keterbatasan sumber daya. Berbeda dengan pendekatan standar, penelitian ini secara spesifik menerapkan strategi *Class Weighting* dan *Fine-Tuning* bertahap untuk memitigasi dampak *imbalance* data, sehingga model dapat mengenali kategori sampah dengan proporsi data sedikit (minoritas) secara lebih adil dan akurat.

METODE

Pengumpulan dan Persiapan Data Dataset yang digunakan dalam penelitian ini mencakup total 6.298 citra sampah yang dikategorikan ke dalam lima kelas utama, yaitu *Cardboard*, *Metal*, *Paper*, *Plastic*, dan *Trash*. Seluruh data diakses melalui lingkungan *Google Colab* dan diekstraksi ke penyimpanan lokal, kemudian dipartisi menjadi dua bagian: 4.272 citra sebagai data latih (*training*) dan 2.026 citra sebagai data validasi. Berdasarkan analisis distribusi, ditemukan adanya ketidakseimbangan dataset (*imbalance*) yang signifikan, di mana kelas *Paper* memiliki jumlah sampel terbanyak sedangkan kelas *Trash* merupakan minoritas 3. Untuk memitigasi bias yang mungkin timbul akibat ketidakseimbangan ini, penelitian menerapkan perhitungan bobot kelas (*class weights*) menggunakan metode '*balanced*' dari pustaka *Scikit-learn*. Pendekatan ini memberikan bobot penalti *loss* yang lebih besar pada kelas minoritas selama proses pelatihan agar model dapat belajar lebih adil.

Preprocessing dan Augmentasi Data sebelum diproses oleh model, dimensi seluruh citra diseragamkan melalui proses *resizing* menjadi 224×224 piksel mengikuti standar input arsitektur *MobileNetV2*. Untuk mencegah *overfitting* dan memperkaya variasi fitur visual, teknik augmentasi data diterapkan pada set pelatihan menggunakan *Image Data Generator* 6. Konfigurasi augmentasi yang diterapkan meliputi *rescaling* nilai piksel sebesar $1/255$, rotasi citra dengan rentang 30 derajat, pergeseran vertikal dan horizontal (*width & height shift*) serta *zoom range* masing-masing sebesar 0,2, pembalikan horizontal (*horizontal flip*), dan penyesuaian kecerahan (*brightness range*) antara 0,8 hingga 1,27.

Arsitektur model dan strategi pelatihan penelitian ini mengadopsi strategi *Transfer Learning* menggunakan base model *MobileNetV2* yang telah dilatih sebelumnya pada dataset *Image Net*, dengan lapisan klasifikasi asli dinonaktifkan (`include_top = False`). Sebagai gantinya, ditambahkan serangkaian lapisan kustom yang terdiri dari *Global Average Pooling 2D*, *Batch Normalization* untuk stabilisasi, *Dense Layer* dengan 256 neuron (aktivasi ReLU), serta lapisan *Dropout* sebesar 0,5 sebagai regularisasi untuk mencegah *overfitting* [9]. Lapisan keluaran (*output layer*) menggunakan 5 neuron dengan fungsi aktivasi *Softmax* sesuai dengan jumlah kelas target 10.

Strategi pelatihan dilakukan dalam dua tahap bertahap. Tahap pertama membekukan sebagian besar lapisan *base* model dan hanya melatih 30 lapisan terakhir bersama lapisan kustom menggunakan *optimizer Adam* dengan *learning rate* $1e-5$. Tahap kedua merupakan proses *Fine-Tuning*, di mana 20 lapisan terakhir dari *base* model dibuka kembali (*unfrozen*) untuk dilatih ulang guna menyesuaikan bobot model dengan fitur spesifik dataset sampah. Fungsi kerugian (*loss function*) yang digunakan adalah *categorical_crossentropy*, dilengkapi dengan callbacks berupa *EarlyStopping (patience 5)* dan *Reduce LR on Plateau* untuk mengoptimalkan proses konvergensi model.

HASIL DAN PEMBAHASAN

Hasil pelatihan proses pelatihan model menunjukkan kinerja konvergensi yang optimal. Pada tahap awal pelatihan, model mampu mencapai akurasi validasi di kisaran 89%, yang kemudian meningkat stabilitasnya setelah penerapan strategi *fine-tuning*. Berdasarkan analisis grafik pelatihan, terlihat bahwa kesenjangan (*gap*) antara akurasi data latih dan akurasi data validasi relatif kecil. Kondisi ini mengindikasikan bahwa teknik regularisasi yang diterapkan, seperti *Dropout* dan augmentasi data, berhasil meminimalisir terjadinya *overfitting* secara efektif. Grafik *loss* juga memperlihatkan tren yang stabil dimana *loss* pada data validasi konstan dan tidak mengalami lonjakan tajam meskipun nilainya lebih tinggi dibandingkan *loss* data latih, yang wajar terjadi akibat perbedaan kompleksitas variasi data.

Evaluasi Performa Model Pengujian akhir menggunakan 2.026 data validasi menunjukkan hasil yang memuaskan dengan Akurasi Total mencapai 90,23%. Metrik evaluasi lainnya juga menunjukkan performa yang solid, dengan *Weighted Precision* sebesar 0,8950, *Weighted Recall* 0,9023, dan *Weighted F1-Score* 0,8759. Analisis mendalam melalui *classification report* memperlihatkan bahwa model sangat efektif dalam mengklasifikasikan material daur ulang utama. Kelas Metal terdeteksi dengan sempurna (*recall* 1.00), diikuti oleh kelas *Paper* dan *Plastic* yang masing-masing mencapai *recall* 0.96. Tingginya akurasi pada kelas-kelas ini membuktikan keandalan arsitektur *MobileNetV2* dalam mengekstraksi fitur bentuk dan tekstur yang tegas dari objek anorganik.

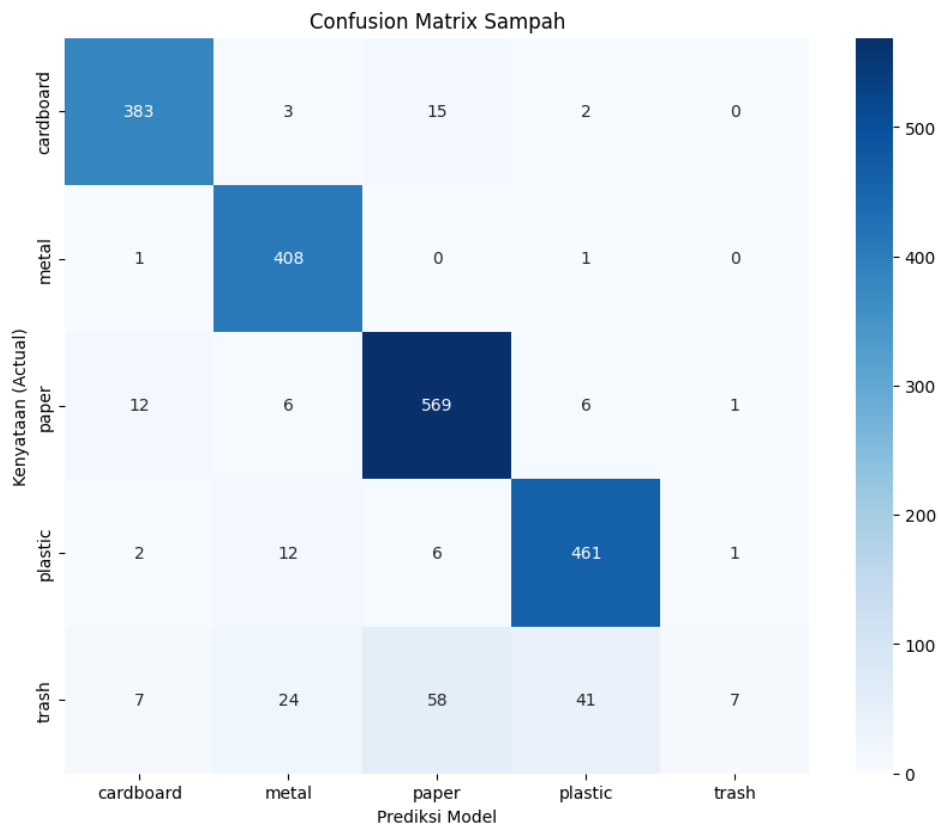
Tabel 1. Laporan Klasifikasi (*Classification Report*)

| Kelas | Precision | Recall | F1- Score | Support |
|-----------|-----------|--------|-----------|---------|
| Cardboard | 0.95 | 0.95 | 0.95 | 403 |
| Metal | 0.90 | 1.00 | 0.95 | 410 |
| Paper | 0.88 | 0.96 | 0.92 | 594 |
| Plastic | 0.90 | 0.96 | 0.93 | 482 |
| Trash | 0.78 | 0.96 | 0.10 | 137 |

Analisis Tabel 1 menunjukkan performa yang sangat impresif pada kelas material daur ulang utama. Kelas Metal terdeteksi dengan sempurna (*recall* 1.00), diikuti oleh *Paper* dan *Plastic* yang mencapai *recall* 0.96. Hal ini membuktikan bahwa *MobileNetV2* sangat efektif dalam mengekstraksi fitur tekstur dan bentuk dari benda-benda anorganik yang memiliki struktur jelas.


Namun, terdapat anomali signifikan pada kelas Trash (sampah residu), di mana nilai *recall* hanya mencapai 0.05. Berdasarkan analisis *Confusion Matrix*, sebagian besar sampel kelas 'Trash' salah diklasifikasikan ke dalam kelas lain. Hal ini kemungkinan disebabkan oleh variasi visual kelas 'Trash'

yang sangat acak dan tidak memiliki pola bentuk yang konsisten seperti botol plastik atau kardus, serta jumlah sampel latihan yang paling sedikit (minoritas) meskipun *class weight* telah diterapkan.



Gambar 1. Confusion Matrix

Visualisasi *Confusion Matrix* pada Gambar 1 memperjelas bahwa sampel *Trash* sering diprediksi sebagai *Paper* atau *Plastic*. Hal ini dapat dimaklumi secara visual karena kategori 'sampah umum' dalam dataset sering kali berupa kertas kotor atau plastik remuk yang memiliki fitur tekstur sangat mirip dengan kategori induknya. Ambiguitas visual ini menjadi tantangan utama bagi model.



Gambar 2. Grafik Akurasi dan Loss dan Validasi

Berdasarkan grafik Akurasi Model, terlihat bahwa akurasi data latih cenderung meningkat seiring bertambahnya *epoch*, meskipun sempat mengalami penurunan pada *epoch* pertama. Pola ini menunjukkan bahwa model mampu mempelajari fitur pada data pelatihan dengan baik. Sementara itu, akurasi data validasi terlihat relatif stabil dengan fluktuasi kecil di sekitar angka 89%. Stabilitas ini, ditambah dengan selisih akurasi yang relatif kecil (sekitar 1–2%) antara data latih dan validasi, mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang tidak dilatih dan tidak mengalami *overfitting* yang signifikan. Dengan demikian, model dapat dikatakan cukup efektif dalam melakukan klasifikasi serta mampu mempertahankan performa yang konsisten pada data baru.

Selanjutnya, pengamatan pada grafik *Loss Model* memperlihatkan bahwa *loss* pada data latih cenderung rendah dan stabil, yang menandakan proses optimasi berjalan dengan baik. Meskipun *loss* pada data validasi tercatat lebih tinggi dibandingkan data latih, nilainya tetap relatif konstan dan tidak menunjukkan peningkatan tajam. Kondisi ini menegaskan bahwa model tidak mengalami *overfitting* berat meskipun terdapat perbedaan kompleksitas antara data latih dan data validasi. Disparitas nilai *loss* antara fase *training* dan *validation* tersebut kemungkinan disebabkan oleh variasi data pada dataset validasi, jumlah data latih yang terbatas, serta kompleksitas fitur yang diekstraksi oleh model.

SIMPULAN DAN SARAN

Penelitian ini berhasil mendemonstrasikan efektivitas *transfer learning* menggunakan MobileNetV2 untuk klasifikasi limbah daur ulang dengan akurasi 90.23%. Pendekatan ini terbukti lebih unggul dibandingkan metode konvensional. Namun, model masih memiliki kelemahan signifikan dalam mengenali kategori sampah residu (*trash*) karena variasi bentuk yang terlalu abstrak. Untuk pengembangan selanjutnya, disarankan untuk: (1) Menambah dataset spesifik untuk kelas residu guna memperkaya variasi fitur; (2) Menerapkan teknik augmentasi yang lebih agresif khusus untuk kelas minoritas; atau (3) Menggunakan arsitektur yang lebih kompleks seperti EfficientNet jika sumber daya komputasi memungkinkan.

DAFTAR PUSTAKA

- [1] Hartono, A. C., & Muslikh, A. R. (2025). Penerapan Transfer Learning Mobilenetv2 Pada Klasifikasi Citra Jenis Buah-Buahan. *Journal Of Information System And Application Development*, 3(2), 103-111.
- [2] Kumala, R. A., Sari, C. A., & Rachmawanto, E. H. 2025. A Comparison Of Mobilenetv2 And VGG16 Architectures With Transfer Learning For Multi-Class Image-Based Waste Classification. *Journal Of Applied Informatics And Computing*, 9(4).
- [3] N. Walliman, *Research Methods: The Basics*, 3rd Ed. London: Routledge, 2021. Doi: 10.4324/9781003141693.
- [4] Thung, G., & Yang, M. 2016. Classification Of Trash For Recyclability Status. *Stanford University Project Report*.
- [5] Yong, L., Ma, L., Sun, D., & Du, L. 2023. Application Of Mobilenetv2 To Waste Classification. *Plos One*, 18(3), E0282336.
- [6] Mark, S., Andrew, H., Menglong, Z., Andrey, Z., Liang-C., Mobilenetv2: Inverted Residuals And Linear Bottlenecks.
- [7] A Comparison Of Mobilenetv2 And VGG16 Architectures With Transfer Learning For Multi-Class Image-Based Waste Classification. *Journal Of Applied Informatics And Computing*, 9(4).
- [8] Yoshua, A, S., Yuita, A, S., Sigit, A. Evaluasi Komparatif Arsitektur Lightweight CNN, Mobilenetv2, Dan Efficientnetb0 Dalam Deteksi Penyakit Daun Jagung.
- [9] Muhammad I, I., Donny, A. Squeeze-And-Excitation Networks And Attention Mechanism In Automatic Detection Of Coffee Leaf Diseases Based On Images.
- [10] Shanshan Meng, W. Chu., A Study Of Garbage Classification With Convolutional Neural Networks.

- [11] Sayalee Suresh Alladwar, M. Hajare, M. Scholar. Deep Learning Techniques Using Garbage Classification
- [12] Q. Aini, N. Lutfiani, H. Kusumah, And M. S. Zahran, "Deteksi Dan Pengenalan Objek Dengan Model Machine Learning: Model YOLO," CESS (Journal Of Computer Engineering System And Science), Vol. 6, No. 2, Jul. 2021. [Online]. Available: <https://doi.org/10.24114/Cess.V6i2.25840>
- [13] T. B. Sasongko, H. Haryoko, And A. Amrullah, "Analisis Efek Augmentasi Dataset Dan Fine Tune Pada Algoritma Pre-Trained Convolutional Neural Network (CNN)," Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK), Vol. 10, No. 4, Pp. 763–768, Aug. 2023. [Online]. Available: <https://doi.org/10.25126/Jtik.2023106583>
- [14] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, And L.-C. Chen, "Mobilenetv2: Inverted Residuals And Linear Bottlenecks," In Proc. 2018 IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR), 2018, Pp. 4510–4520. [Online]. Available: <https://doi.org/10.1109/CVPR.2018.00474>
- [15] U. Ozkaya, L. Seyfi. Fine-Tuning Models Comparisons On Garbage Classification For Recyclability