Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

Klasifikasi Citra Sampah Menggunakan Convolutional Neural Network dengan Arsitektur MobileNetV2

Jubel K Aritonang*✉, Jenly Imuly✉, Adit Maulana Ardiansyah✉, Rachmat Adi Purnama✉, Veti Apriana✉, Sujiliani Heristian✉
Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, Indonesia

Abstrak

Pengelolaan sampah membutuhkan proses pemilahan yang tepat untuk mendukung penanganan sampah berdasarkan jenisnya. Identifikasi secara manual masih memiliki keterbatasan dalam efisiensi dan konsistensi, terutama ketika objek memiliki karakteristik visual yang beragam. Selain itu, sistem klasifikasi sampah perlu mampu membedakan objek sampah dari objek yang bukan sampah. Penelitian ini bertujuan mengembangkan dan mengevaluasi sistem klasifikasi citra menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2. Penelitian menerapkan pendekatan *Transfer Learning* melalui dua eksperimen, yaitu *Feature Extraction* dan *Fine-Tuning*, untuk mengklasifikasikan citra ke dalam tiga kategori, yaitu organik, anorganik, dan bukan sampah. Dataset yang digunakan berjumlah 8.657 citra, terdiri atas 6.060 citra pelatihan, 1.299 citra validasi, dan 1.298 citra pengujian. Tahapan penelitian meliputi seleksi dataset, prapemrosesan citra, augmentasi data, pelatihan model, dan evaluasi menggunakan metrik *accuracy*, *precision*, *recall*, serta *F1-score*. Hasil pengujian menunjukkan bahwa model *Fine-Tuning* memperoleh *accuracy* sebesar 93,76%, *macro precision* sebesar 93,18%, *macro recall* sebesar 94,35%, dan *macro F1-score* sebesar 93,74%. Pada kategori bukan sampah, model memperoleh *precision* sebesar 91,54% dan *recall* sebesar 95,97%, yang menunjukkan kemampuan model dalam mengenali objek bukan sampah pada dataset pengujian. Hasil penelitian menunjukkan bahwa pendekatan *Fine-Tuning* memberikan performa lebih baik dibandingkan *Feature Extraction* dalam klasifikasi ketiga kategori citra.
Kata Kunci: Waste Image Classification; MobileNetV2; Transfer Learning; Non-Waste Detection; Deep Learning.

Abstract

Waste management requires accurate sorting processes to support the appropriate handling of different waste categories. Manual identification still has limitations in terms of efficiency and consistency, particularly when objects exhibit diverse visual characteristics. Furthermore, waste classification systems need to distinguish waste objects from non-waste objects. This study aims to develop and evaluate an image classification system using a Convolutional Neural Network (CNN) with the MobileNetV2 architecture. The study employs a Transfer Learning approach through two experiments, namely Feature Extraction and Fine-Tuning, to classify images into three categories: organic waste, inorganic waste, and non-waste. The dataset consists of 8,657 images, including 6,060 training images, 1,299 validation images, and 1,298 testing images. The research stages include dataset selection, image preprocessing, data augmentation, model training, and performance evaluation using accuracy, precision, recall, and F1-score metrics. The testing results show that the Fine-Tuning model achieves an accuracy of 93.76%, macro precision of 93.18%, macro recall of 94.35%, and macro F1-score of 93.74%. For the non-waste category, the model achieves a precision of 91.54% and a recall of 95.97%, indicating its ability to recognize non-waste objects in the testing dataset. These findings demonstrate that the Fine-Tuning approach provides better classification performance than Feature Extraction across the three image categories.
Keywords: Waste Image Classification; MobileNetV2; Transfer Learning; Non-Waste Detection; Deep Learning

***Corresponding Author:**
Jubel K Aritonang, Universitas Bina Sarana Informatika, Indonesia
Email: jubelart669@gmail.com

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

1. PENDAHULUAN

Pengelolaan sampah merupakan salah satu permasalahan lingkungan yang membutuhkan perhatian serius [1]. Peningkatan jumlah sampah seiring dengan aktivitas masyarakat menjadikan proses pemilahan sebagai tahapan penting dalam pengelolaan sampah [2]. Pemilahan yang tepat dapat membantu menentukan metode pengolahan dan penanganan sesuai dengan karakteristik sampah [3]. Namun, identifikasi yang dilakukan secara manual memiliki keterbatasan, seperti membutuhkan waktu, bergantung pada ketelitian manusia, dan berpotensi menimbulkan kesalahan dalam membedakan jenis sampah [4],[5] menjelaskan bahwa pemilahan sampah organik dan anorganik secara manual rentan terhadap kesalahan manusia dan kurang efisien. Perkembangan teknologi computer vision dan kecerdasan buatan memberikan peluang untuk membantu proses identifikasi sampah secara otomatis berdasarkan karakteristik visual citra, seperti yang dikemukakan [6], [7]

Penelitian mengenai klasifikasi citra sampah telah dikembangkan menggunakan metode Convolutional Neural Network (CNN) dan transfer learning dengan karakteristik dataset serta pendekatan evaluasi yang beragam, [8], [9], [5] menggunakan dataset Waste Classification Data dari Kaggle untuk mengklasifikasikan sampah ke dalam dua kelas, yaitu organik dan non-organik. Penelitian tersebut membandingkan tiga arsitektur, yaitu VGG16, MobileNetV2, dan ResNet50V2. Hasil pengujian menunjukkan bahwa MobileNetV2 memperoleh akurasi sebesar 90,13%, precision 96,25%, dan F1-score 87,88%. Penelitian ini memberikan perbandingan kinerja beberapa arsitektur, tetapi ruang lingkup klasifikasinya masih berfokus pada dua kategori sampah.

Penelitian [10] menerapkan CNN dengan arsitektur MobileNetV2 untuk klasifikasi multikelas menggunakan 15.515 citra yang dikelompokkan ke dalam 12 kategori sampah. Proses pengembangan model mencakup preprocessing, augmentasi data, feature extraction, dan fine-tuning. Evaluasi pada data pengujian menghasilkan accuracy 94,97%, macro precision 93,37%, macro recall 92,53%, dan macro F1-score 92,85%. Sementara itu, [11] membandingkan CNN dan MobileNetV2 menggunakan 2.527 citra yang terdiri atas enam kelas, yaitu plastik, kertas, kaca, logam, kardus, dan sampah lainnya. Penelitian tersebut menerapkan augmentasi data, transfer learning, serta teknik optimasi seperti dropout, penyesuaian learning rate, dan early stopping. Hasil evaluasi menunjukkan bahwa MobileNetV2 memperoleh akurasi validasi sebesar 69,8%, sedangkan CNN memperoleh 48,5%. Kedua penelitian tersebut menunjukkan penerapan MobileNetV2 pada klasifikasi sampah dengan jumlah kategori dan strategi pelatihan yang berbeda. Namun, kategori yang digunakan masih berfokus pada jenis atau material sampah dan belum secara khusus mengevaluasi kemampuan model dalam membedakan citra sampah dari citra yang tidak mengandung objek sampah.

Berdasarkan penelitian-penelitian tersebut, klasifikasi citra sampah telah dikembangkan untuk mengenali berbagai jenis dan material sampah dengan jumlah kategori yang beragam. Namun, kemampuan model dalam membedakan citra yang mengandung sampah dan citra yang tidak mengandung objek sampah masih menjadi aspek yang perlu dikaji secara khusus, sejalan dengan tantangan deteksi data di luar kelas utama [12], [13]. Tantangan tersebut berkaitan dengan kemungkinan model memberikan prediksi kategori sampah terhadap citra yang sebenarnya bukan sampah. Oleh karena itu, penelitian ini mengembangkan klasifikasi tiga kelas, yaitu organik, anorganik, dan bukan sampah. Kelas bukan sampah digunakan sebagai kategori pembeda agar evaluasi tidak hanya mengukur kemampuan model dalam mengenali jenis sampah, tetapi juga kemampuannya mengenali citra yang tidak termasuk objek sampah. Evaluasi dilakukan menggunakan metrik pada tingkat keseluruhan maupun masing-masing kelas, terutama precision, recall, dan F1-score kelas bukan sampah.

Dataset yang digunakan dalam penelitian ini berjumlah 8.657 citra yang telah melalui tahapan pemeriksaan dan persiapan data. Dataset dibagi menjadi 6.060 citra untuk pelatihan (training), 1.299 citra untuk validasi (validation), dan 1.298 citra untuk pengujian (testing). Seluruh citra diseragamkan ke ukuran 224 × 224 piksel sebagai masukan model. Pengembangan model menggunakan metode CNN dengan arsitektur MobileNetV2 [14], [15] melalui pendekatan transfer learning, dengan memanfaatkan bobot pralatih (pre-trained weights) dari dataset ImageNet. Pelatihan dilakukan melalui dua tahap, yaitu feature extraction dan fine-tuning, untuk memanfaatkan fitur yang telah dipelajari sebelumnya sekaligus menyesuaikan sebagian parameter model terhadap karakteristik dataset penelitian, [16].

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

Penelitian ini bertujuan untuk mengembangkan model klasifikasi citra sampah menggunakan CNN dengan arsitektur MobileNetV2 untuk mengenali kategori organik, anorganik, dan bukan sampah. Kinerja model dievaluasi menggunakan accuracy, precision, recall, F1-score, dan confusion matrix, dengan perhatian khusus pada hasil klasifikasi kelas bukan sampah. Selain itu, model terlatih dikembangkan untuk diintegrasikan ke dalam aplikasi web EcoVision AI berbasis Flask agar pengguna dapat mengunggah citra dan memperoleh hasil klasifikasi beserta nilai confidence, serupa dengan pengembangan berbasis web [17] .Kontribusi penelitian ini terletak pada penerapan dan evaluasi MobileNetV2 untuk klasifikasi tiga kelas yang secara eksplisit mencakup kategori bukan sampah, serta analisis kinerja setiap kelas untuk mengetahui kemampuan model dalam membedakan objek sampah dan bukan sampah. Dengan demikian, evaluasi penelitian tidak hanya didasarkan pada nilai akurasi keseluruhan, tetapi juga mempertimbangkan kesalahan klasifikasi dan kinerja pada setiap kategori.

2. METODE PENELITIAN

2.1. Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang meliputi pemeriksaan dataset, pembagian data, preprocessing citra, augmentasi data, perancangan model, pelatihan, dan evaluasi. Dataset terdiri atas tiga kelas, yaitu organik, anorganik, dan bukan sampah. Sebelum digunakan, seluruh citra diperiksa untuk mengidentifikasi file yang rusak, citra berukuran terlalu kecil, serta duplikat berdasarkan nilai hash SHA-256. Hasil pemeriksaan menunjukkan bahwa seluruh citra pada dataset akhir dinyatakan valid dan tidak ditemukan duplikat identik antarpembagian data. Dataset kemudian dibagi menjadi data pelatihan (*training*) sebanyak 6.060 citra, data validasi (*validation*) sebanyak 1.299 citra, dan data pengujian (*testing*) sebanyak 1.298 citra, sehingga total dataset yang digunakan berjumlah 8.657 citra. Pembagian data dilakukan dengan proporsi mendekati 70:15:15 dan menggunakan *random seed* 42. Tahap berikutnya adalah preprocessing untuk menyiapkan citra sesuai dengan kebutuhan masukan

Proses ini meliputi penyesuaian orientasi citra berdasarkan informasi EXIF, konversi format warna menjadi RGB, dan perubahan ukuran citra menjadi 224 × 224 piksel. Citra hasil preprocessing disimpan dalam format JPEG. Pada tahap masukan model, nilai piksel disesuaikan menggunakan fungsi preprocessing MobileNetV2 sehingga berada pada rentang -1 hingga 1. Selanjutnya, augmentasi data diterapkan secara daring (*online augmentation*) hanya pada data training untuk meningkatkan variasi citra selama pelatihan. Teknik augmentasi yang digunakan meliputi pembalikan horizontal (*horizontal flip*), rotasi dengan faktor 0,05, pembesaran atau pengecilan citra (*zoom*) sebesar 0,10, serta penyesuaian kontras sebesar 0,10. Data validation dan testing tidak diberikan augmentasi acak agar proses pemantauan dan evaluasi tetap menggunakan citra tanpa transformasi augmentasi.

Perancangan model dilakukan menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 yang memanfaatkan bobot pralatih (*pre-trained weights*) dari ImageNet. Bagian dasar MobileNetV2 digunakan sebagai ekstraktor fitur, kemudian ditambahkan lapisan *Global Average Pooling*, *Dropout* sebesar 0,30, lapisan *Dense* dengan 128 unit dan fungsi aktivasi ReLU, *Dropout* sebesar 0,30, serta lapisan keluaran dengan tiga unit dan fungsi aktivasi Softmax. Model memiliki total 2.422.339 parameter. Pelatihan dilakukan melalui dua tahap, yaitu *feature extraction* dan *fine-tuning*. Pada tahap *feature extraction*, lapisan dasar MobileNetV2 dibekukan untuk mempertahankan bobot pralatih, sedangkan lapisan klasifikasi dilatih menggunakan optimizer Adam dengan *learning rate* 0,001 dan maksimum 10 epoch. Pada tahap *fine-tuning*, sebanyak 19 lapisan bagian akhir *backbone* dibuka untuk dilatih kembali, sedangkan lapisan *Batch Normalization* tetap dibekukan. Tahap ini menggunakan optimizer Adam dengan *learning rate* 0,00001 dan maksimum 8 epoch. Kedua tahap menggunakan *batch size* 16, fungsi *loss* Sparse Categorical Crossentropy, serta *class weighting* untuk mempertimbangkan ketidakseimbangan jumlah citra antarkelas. Proses pelatihan juga menggunakan *Early Stopping* dengan *patience* 3 dan *ReduceLROnPlateau* dengan *patience* 2 serta faktor penurunan *learning rate* sebesar 0,2.

Tahap terakhir adalah evaluasi model menggunakan data testing yang tidak digunakan dalam proses pelatihan maupun validasi. Evaluasi dilakukan terhadap kedua model hasil pelatihan, yaitu model *feature extraction* dan *fine-tuning*, untuk mengetahui perbedaan kinerjanya. Metrik evaluasi yang

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

digunakan meliputi accuracy, precision, recall, dan F1-score, baik secara keseluruhan maupun pada masing-masing kelas. Selain itu, *confusion matrix* digunakan untuk menganalisis jumlah prediksi benar dan kesalahan klasifikasi pada ketiga kategori. Perhatian khusus diberikan pada kelas bukan sampah untuk mengetahui kemampuan model dalam membedakan citra yang mengandung sampah dan citra yang tidak mengandung objek sampah. Model dengan hasil evaluasi terbaik kemudian dipilih sebagai model akhir untuk digunakan pada aplikasi web EcoVision AI berbasis Flask.

2.2. Dataset Penelitian

Dataset yang digunakan dalam penelitian ini terdiri atas tiga kategori citra, yaitu sampah organik, sampah anorganik, dan bukan sampah. Citra sampah organik dan anorganik diperoleh dari dataset *Waste Classification Data* yang tersedia pada Kaggle (https://www.kaggle.com/datasets/techsash/waste-classification-data). Dataset tersebut menyediakan citra sampah yang dikelompokkan berdasarkan kategori organik dan dapat didaur ulang (*recyclable*). Dalam penelitian ini, citra kategori organik digunakan sebagai kelas organik, sedangkan citra kategori *recyclable* digunakan sebagai kelas anorganik. Sementara itu, citra kategori bukan sampah diperoleh dari dataset *Caltech-101* yang tersedia pada Kaggle (https://www.kaggle.com/datasets/imbikramsaha/caltech-101). Citra dari dataset Caltech-101 diseleksi secara manual dengan memilih objek yang tidak termasuk sampah dan tidak merepresentasikan material buangan.

Penentuan label dilakukan berdasarkan karakteristik objek utama pada citra. Kategori organik mencakup objek sampah yang berasal dari bahan hayati, seperti sisa makanan, buah, dan sayuran. Kategori anorganik mencakup objek sampah dari material nonhayati atau material yang dapat didaur ulang, seperti plastik, kertas, kaca, dan logam. Adapun kategori bukan sampah mencakup citra objek yang tidak merepresentasikan sampah, seperti hewan, kendaraan, bangunan, dan objek sehari-hari lainnya. Seleksi citra dilakukan untuk memastikan objek utama sesuai dengan kategori yang ditetapkan. Citra yang tidak sesuai dengan kriteria kategori penelitian tidak digunakan dalam dataset.

Setelah proses pengumpulan dan seleksi, dataset diperiksa untuk mengidentifikasi file citra yang rusak, citra dengan ukuran terlalu kecil, serta duplikat. Pemeriksaan duplikat dilakukan menggunakan algoritma SHA-256 dengan membandingkan nilai hash setiap file citra pada pembagian dataset. Hasil pemeriksaan menunjukkan tidak ditemukan duplikat identik berdasarkan kesamaan nilai hash antarpembagian data. Pemeriksaan tersebut digunakan untuk mengidentifikasi file yang memiliki isi biner sama, tetapi tidak secara otomatis mendeteksi citra yang secara visual mirip meskipun telah mengalami perubahan ukuran, kompresi, atau format.

Dataset kemudian dibagi menjadi data pelatihan (*training*), data validasi (*validation*), dan data pengujian (*testing*) sebelum proses augmentasi dilakukan. Pembagian ini bertujuan untuk memastikan bahwa citra yang digunakan untuk pengujian tidak menjadi bagian dari proses pembelajaran model. Dataset akhir terdiri atas 8.657 citra, dengan 6.060 citra untuk pelatihan, 1.299 citra untuk validasi, dan 1.298 citra untuk pengujian. Rincian distribusi dataset berdasarkan kategori ditampilkan pada Tabel 1.

Tabel 1. Distribusi Dataset Penelitian

Kategori	Training	Validation	Testing	Total
Organik	2.700	579	578	3.857
Anorganik	2.782	596	596	3.974
Bukan sampah	578	124	124	826
Total	**6.060**	**1.299**	**1.298**	**8.657**

Berdasarkan Tabel 1, kategori anorganik memiliki jumlah citra terbanyak, yaitu 3.974 citra, sedangkan kategori bukan sampah memiliki jumlah paling sedikit, yaitu 826 citra. Perbedaan jumlah tersebut menjadi pertimbangan dalam proses pelatihan dengan menerapkan *class weighting* agar ketidakseimbangan jumlah data antarkelas turut diperhatikan. Selain itu, evaluasi model dilakukan menggunakan metrik pada setiap kelas, khususnya precision, recall, dan F1-score, untuk mengetahui kemampuan model dalam mengenali kategori organik, anorganik, dan bukan sampah.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

2.3. Preprocessing dan Augmentasi Citra

Tahap preprocessing dilakukan untuk menyiapkan citra agar sesuai dengan kebutuhan masukan model MobileNetV2. Proses diawali dengan pemeriksaan integritas citra untuk mengidentifikasi file yang rusak dan citra dengan ukuran terlalu kecil. Selanjutnya, dilakukan pemeriksaan duplikat identik menggunakan algoritma *Secure Hash Algorithm 256* (SHA-256) dengan membandingkan nilai hash setiap file citra pada pembagian dataset. Hasil pemeriksaan menunjukkan bahwa seluruh citra pada dataset akhir dinyatakan valid dan tidak ditemukan duplikat identik antarpembagian data berdasarkan nilai hash. Pemeriksaan ini digunakan untuk mengidentifikasi file dengan isi biner yang sama, tetapi tidak secara langsung mendeteksi citra yang memiliki kemiripan visual setelah mengalami perubahan ukuran, kompresi, atau format.

Setelah pemeriksaan integritas, citra diproses melalui penyesuaian orientasi berdasarkan informasi EXIF, konversi format warna menjadi RGB dengan tiga kanal warna, dan perubahan ukuran menjadi 224 × 224 piksel. Citra hasil preprocessing kemudian disimpan dalam format JPEG. Pada tahap masukan model, nilai piksel yang semula berada pada rentang 0–255 disesuaikan menggunakan fungsi *preprocess_input* dari TensorFlow Keras MobileNetV2 sehingga berada pada rentang −1 hingga 1. Penyesuaian tersebut dilakukan agar representasi nilai piksel sesuai dengan kebutuhan arsitektur MobileNetV2 yang menggunakan bobot pralatih ImageNet.

Augmentasi citra diterapkan secara daring (*online augmentation*) selama proses pelatihan dan hanya pada data *training*. Teknik augmentasi yang digunakan meliputi *Random Flip* secara horizontal, *Random Rotation* dengan faktor 0,05, *Random Zoom* sebesar 0,10, dan *Random Contrast* sebesar 0,10. Penerapan augmentasi bertujuan meningkatkan variasi tampilan citra selama proses pembelajaran sehingga model dapat mempelajari karakteristik objek dari berbagai kondisi visual. Sementara itu, data *validation* dan *testing* tidak diberikan augmentasi acak agar proses pemantauan dan evaluasi dilakukan menggunakan citra yang tidak mengalami transformasi augmentasi.

Tabel 2. Parameter Preprocessing dan Augmentasi Citra

Tahapan	Parameter
Penyesuaian orientasi	Berdasarkan informasi EXIF
Konversi warna	RGB (3 kanal)
Resize	224 × 224 piksel
Format penyimpanan	JPEG
Normalisasi	*preprocess_input* MobileNetV2, rentang −1 hingga 1
Random Flip	Horizontal
Random Rotation	0,05
Random Zoom	0,10
Random Contrast	0,10
Penerapan augmentasi	Hanya data training

Dengan urutan tersebut, seluruh citra terlebih dahulu melalui pemeriksaan dan preprocessing sebelum digunakan sebagai masukan model. Augmentasi diterapkan hanya pada data pelatihan, sedangkan data validasi dan pengujian dipertahankan tanpa augmentasi acak untuk menjaga konsistensi evaluasi kinerja model.

2.4. Perancangan Model CNN dengan MobileNetV2

Model klasifikasi pada penelitian ini dibangun menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2. Arsitektur ini dipilih karena memiliki struktur jaringan yang efisien dalam mengekstraksi fitur visual dengan kebutuhan komputasi yang relatif ringan. Model dikembangkan menggunakan pendekatan *Transfer Learning* dengan memanfaatkan bobot pralatih (*pretrained weights*) dari ImageNet. Pendekatan ini memungkinkan model menggunakan fitur visual yang telah dipelajari sebelumnya, kemudian menyesuaikannya dengan karakteristik citra sampah pada dataset penelitian.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

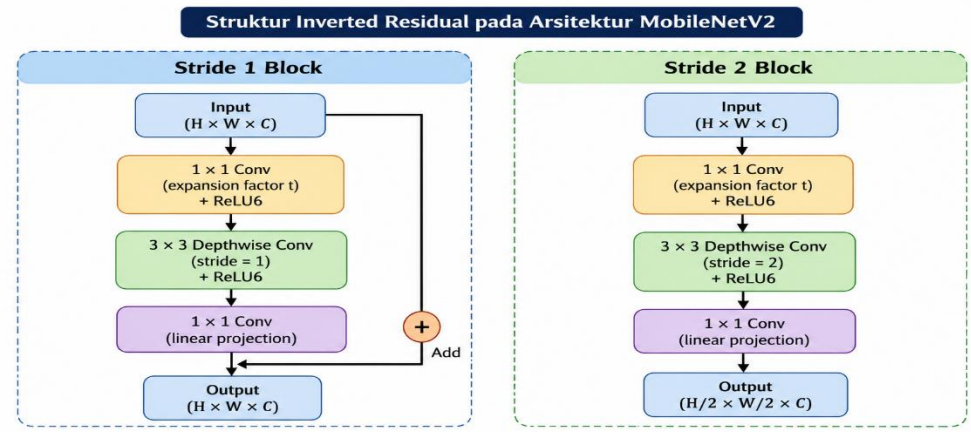

Gambar 1. Struktur Inverted Residual pada Arsitektur MobileNetV2

Gambar 1 memperlihatkan dua jenis blok utama pada MobileNetV2, yaitu *stride 1 block* dan *stride 2 block*. Blok *stride 1* menggunakan koneksi residual (*add*) untuk menghubungkan masukan dengan keluaran apabila dimensi keduanya sesuai. Sementara itu, blok *stride 2* digunakan untuk mengurangi ukuran spasial fitur melalui operasi konvolusi dengan langkah (*stride*) sebesar dua. MobileNetV2 mengombinasikan *pointwise convolution*, *depthwise convolution*, dan *linear projection* untuk mengekstraksi fitur secara efisien. Ilustrasi tersebut menggambarkan prinsip kerja blok *inverted residual* pada MobileNetV2 dan bukan keseluruhan susunan lapisan model yang digunakan dalam penelitian ini.

Pada penelitian ini, citra masukan memiliki ukuran 224 × 224 piksel dengan tiga kanal warna RGB. Sebelum masuk ke model, citra diproses menggunakan fungsi *preprocess_input* dari TensorFlow Keras MobileNetV2. Fungsi tersebut menyesuaikan rentang nilai piksel dari 0–255 menjadi -1 hingga 1 agar sesuai dengan format masukan yang digunakan pada bobot pralatih ImageNet. Selanjutnya, citra diteruskan ke bagian dasar (*base model*) MobileNetV2 untuk memperoleh representasi fitur visual (*feature maps*). Proses pelatihan dilakukan melalui dua skenario, yaitu *Feature Extraction* dengan seluruh lapisan dasar dibekukan (*frozen*) dan *Fine-Tuning* dengan membuka sebagian lapisan dasar untuk diperbarui bobotnya.

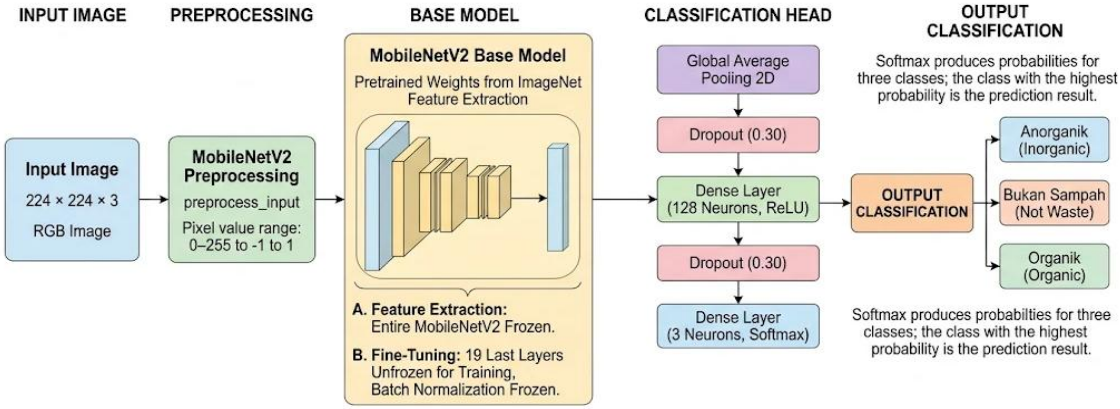

Gambar 2. Arsitektur Model CNN dengan MobileNetV2 pada EcoVision AI

Berdasarkan Gambar 2, fitur visual yang dihasilkan oleh MobileNetV2 diteruskan ke bagian klasifikasi (*classification head*). Bagian ini diawali dengan lapisan *Global Average Pooling 2D* untuk merangkum informasi fitur dari setiap peta fitur menjadi sebuah vektor. Selanjutnya, digunakan lapisan *Dropout* sebesar 0,30 untuk mengurangi risiko *overfitting*, kemudian lapisan *Dense* dengan 128 neuron dan fungsi aktivasi ReLU untuk mempelajari representasi fitur. Lapisan *Dropout* sebesar 0,30 kembali diterapkan sebelum lapisan keluaran. Lapisan keluaran menggunakan *Dense* dengan tiga neuron dan fungsi aktivasi Softmax untuk menghasilkan probabilitas pada tiga kelas, yaitu anorganik,

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

bukan sampah, dan organik. Kelas dengan probabilitas tertinggi ditetapkan sebagai hasil prediksi model.

Proses ekstraksi fitur pada CNN melibatkan operasi konvolusi untuk memperoleh informasi penting dari citra masukan. Secara matematis, operasi konvolusi sederhana dapat dinyatakan sebagai berikut:

$$Y(i,j) = \sum_m \sum_n X\,(i-m, j-n)K(m,n)$$

Keterangan:

- (X) merupakan citra masukan.
- (K) merupakan kernel atau filter konvolusi.
- (Y) merupakan hasil operasi konvolusi.
- (i,j) merupakan posisi piksel pada citra keluaran.

Pada bagian klasifikasi, lapisan Dense menggunakan fungsi aktivasi ReLU untuk memperkenalkan sifat nonlinier dalam proses pembelajaran fitur. Fungsi ReLU dirumuskan sebagai berikut:

$$\mathrm{K}f(x) = \max(0, x)$$

Selanjutnya, lapisan keluaran menggunakan fungsi aktivasi Softmax untuk mengubah nilai keluaran model menjadi probabilitas pada masing-masing kelas. Fungsi Softmax dirumuskan sebagai berikut:

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^{C} e^{z_j}}$$

Keterangan:

- (z_i) merupakan nilai keluaran model untuk kelas ke-(i).
- (C) merupakan jumlah kelas.
- (P(y_i)) merupakan probabilitas prediksi pada kelas ke-(i).

Dalam penelitian ini, jumlah kelas ((C)) adalah tiga. Kelas dengan nilai probabilitas tertinggi menjadi hasil prediksi klasifikasi.

Untuk mengetahui pengaruh pembaruan bobot pada bagian dasar MobileNetV2, penelitian ini menggunakan dua skenario eksperimen, yaitu *Feature Extraction* dan *Fine-Tuning*. Pada skenario *Feature Extraction*, seluruh lapisan dasar MobileNetV2 dibekukan sehingga bobot pralatih dari ImageNet tidak diperbarui selama pelatihan. Pembaruan bobot hanya dilakukan pada lapisan klasifikasi yang ditambahkan. Model pada tahap ini memiliki total 2.422.339 parameter, yang terdiri atas 164.355 parameter *trainable* dan 2.257.984 parameter *non-trainable*.

Pada skenario *Fine-Tuning*, sebagian lapisan dasar MobileNetV2 dibuka agar bobotnya dapat diperbarui selama proses pelatihan. Sebanyak 19 lapisan terakhir pada *base model* diaktifkan untuk pelatihan, sedangkan lapisan *Batch Normalization* tetap dibekukan. Strategi ini bertujuan agar sebagian fitur yang telah dipelajari dari ImageNet dapat disesuaikan dengan karakteristik citra sampah pada dataset penelitian. Jumlah total parameter model tetap sebanyak 2.422.339 parameter, sedangkan jumlah parameter *trainable* dan *non-trainable* mengikuti pengaturan lapisan yang dibuka pada tahap *Fine-Tuning*.

Tabel 3. Konfigurasi Pelatihan pada Kedua Skenario

Parameter	Feature Extraction	Fine-Tuning
Ukuran citra	224 × 224	224 × 224
Batch size	16	16
Maksimum epoch	10	8
Optimizer	Adam	Adam
Learning rate awal	0,001	0,00001
Fungsi loss	Categorical Crossentropy	Categorical Crossentropy
Metrik pelatihan	Accuracy	Accuracy

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

Random seed	42	42
Lapisan dasar MobileNetV2	Seluruhnya dibekukan	19 lapisan terakhir dibuka
Batch Normalization	Dibekukan	Dibekukan
Total parameter	2.422.339	2.422.339
Trainable parameters	164.355	[sesuaikan dengan model.summary()]
Non-trainable parameters	2.257.984	[sesuaikan dengan model.summary()]

Proses pelatihan menggunakan optimizer Adam dengan fungsi kerugian (*loss function*) *categorical crossentropy*. Untuk memperhitungkan perbedaan jumlah citra pada setiap kelas, pelatihan juga menerapkan *class weight*. Nilai bobot kelas yang digunakan adalah 0,726096 untuk kelas anorganik, 3,494810 untuk kelas bukan sampah, dan 0,748148 untuk kelas organik. Penerapan bobot kelas tersebut bertujuan memberikan perhatian lebih besar terhadap kelas yang memiliki jumlah data lebih sedikit selama proses pembelajaran.

Pengendalian proses pelatihan dilakukan menggunakan beberapa *callback*. *ModelCheckpoint* digunakan untuk menyimpan model dengan nilai *validation loss* terbaik melalui pengaturan save_best_only=True. Selanjutnya, *EarlyStopping* digunakan untuk menghentikan pelatihan apabila nilai *validation loss* tidak mengalami perbaikan selama tiga epoch berturut-turut (patience=3), dengan pengaturan restore_best_weights=True agar bobot model dikembalikan ke kondisi terbaik. *ReduceLROnPlateau* digunakan untuk menurunkan nilai *learning rate* ketika *validation loss* tidak mengalami perbaikan selama dua epoch (patience=2), dengan faktor penurunan sebesar 0,2 (factor=0.2) dan nilai minimum *learning rate* sebesar 0,0000001 (min_lr=0.0000001). Selain itu, *CSVLogger* digunakan untuk mencatat riwayat pelatihan ke dalam berkas CSV sehingga perkembangan nilai metrik selama pelatihan dapat dianalisis.

Pengaturan eksperimen menggunakan *random seed* 42 untuk membantu menjaga konsistensi proses pengacakan. Pada skenario *Feature Extraction*, nilai seed diterapkan pada proses pengacakan dataset. Sementara itu, pada skenario *Fine-Tuning*, seed diterapkan pada pengaturan generator acak Python, NumPy, TensorFlow, serta proses pengacakan dataset. Meskipun demikian, penggunaan *random seed* tidak menjamin hasil pelatihan yang sepenuhnya identik pada setiap eksekusi karena proses komputasi tertentu dapat bersifat nondeterministik.

Implementasi model dilakukan menggunakan Python versi 3.14.6, TensorFlow versi 2.22.0-rc0, dan Keras versi 3.16.0.dev2026111003. Eksperimen dijalankan pada sistem operasi Windows 11 dengan prosesor Intel Core i3-N305 dan RAM sebesar 8 GB. Proses pelatihan dilakukan menggunakan CPU tanpa akselerasi GPU. Informasi perangkat lunak dan perangkat keras tersebut dicantumkan untuk menjelaskan lingkungan komputasi yang digunakan selama eksperimen.

Kedua skenario model dievaluasi menggunakan data pengujian yang sama dan tidak digunakan selama proses pelatihan maupun validasi. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengetahui kemampuan model dalam mengklasifikasikan citra ke dalam tiga kelas. Hasil pengujian menunjukkan bahwa skenario *Feature Extraction* memperoleh *accuracy* sebesar 91,29%, sedangkan skenario *Fine-Tuning* memperoleh *accuracy* sebesar 93,76%. Selain itu, nilai *macro F1-score* meningkat dari 90,53% pada *Feature Extraction* menjadi 93,74% pada *Fine-Tuning*. Hasil tersebut menunjukkan bahwa pembaruan sebagian bobot pada lapisan dasar MobileNetV2 memberikan kinerja klasifikasi yang lebih baik pada dataset penelitian. Oleh karena itu, model *Fine-Tuning* dipilih sebagai model akhir yang digunakan dalam pengembangan EcoVision AI.

2.5. Proses Pelatihan Model

Proses pelatihan model dilakukan menggunakan TensorFlow dan Keras dengan optimizer Adam serta fungsi kerugian (*loss function*) *categorical crossentropy*. Metrik *accuracy* digunakan untuk memantau kinerja model selama proses pelatihan dan validasi. Eksperimen dilakukan melalui dua skenario, yaitu

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

Feature Extraction dan *Fine-Tuning*. Pada skenario *Feature Extraction*, seluruh lapisan dasar MobileNetV2 dibekukan sehingga bobot pralatih ImageNet tidak diperbarui. Pembaruan parameter hanya dilakukan pada bagian *classification head*. Pelatihan menggunakan ukuran citra 224 × 224 piksel, *batch size* 16, maksimum 10 epoch, dan *learning rate* sebesar 0,001.

Pada skenario *Fine-Tuning*, sebanyak 19 lapisan terakhir pada *base model* MobileNetV2 dibuka agar bobotnya dapat diperbarui selama proses pelatihan, sedangkan lapisan *Batch Normalization* tetap dibekukan. Pengaturan pelatihan menggunakan ukuran citra 224 × 224 piksel, *batch size* 16, maksimum 8 epoch, dan *learning rate* sebesar 0,00001. Nilai *learning rate* yang lebih kecil digunakan untuk memperbarui bobot pralatih secara bertahap agar penyesuaian fitur terhadap karakteristik dataset penelitian dapat dilakukan secara lebih hati-hati.

Untuk memperhitungkan ketidakseimbangan jumlah citra antarkelas, proses pelatihan menerapkan *class weight*. Bobot yang digunakan adalah 0,726096 untuk kelas anorganik, 3,494810 untuk kelas bukan sampah, dan 0,748148 untuk kelas organik. Penerapan bobot kelas bertujuan memberikan kontribusi kerugian yang lebih besar pada kelas dengan jumlah data lebih sedikit selama proses pembelajaran.

Pengendalian proses pelatihan dilakukan menggunakan beberapa mekanisme *callback*, yaitu *ModelCheckpoint*, *EarlyStopping*, *ReduceLROnPlateau*, dan *CSVLogger*. *ModelCheckpoint* digunakan untuk menyimpan model dengan nilai *validation loss* terbaik melalui pengaturan monitor="val_loss" dan save_best_only=True. *EarlyStopping* diterapkan dengan patience=3 dan restore_best_weights=True untuk menghentikan pelatihan apabila nilai *validation loss* tidak mengalami perbaikan selama tiga epoch berturut-turut serta mengembalikan bobot model ke kondisi terbaik. Selanjutnya, *ReduceLROnPlateau* digunakan untuk menurunkan *learning rate* apabila nilai *validation loss* tidak mengalami perbaikan selama dua epoch, dengan faktor penurunan sebesar 0,2 (factor=0.2), patience=2, dan *minimum learning rate* sebesar 0,0000001. Sementara itu, *CSVLogger* digunakan untuk mencatat riwayat pelatihan ke dalam berkas CSV sehingga perkembangan metrik selama pelatihan dapat dianalisis.

Pengaturan *random seed* sebesar 42 diterapkan untuk membantu menjaga konsistensi proses pengacakan. Pada skenario *Feature Extraction*, nilai seed digunakan pada proses pengacakan dataset. Sementara itu, pada skenario *Fine-Tuning*, pengaturan seed juga diterapkan pada generator acak Python, NumPy, dan TensorFlow, serta proses pengacakan dataset. Meskipun demikian, penggunaan *random seed* tidak menjamin hasil yang sepenuhnya identik pada setiap eksekusi karena beberapa operasi komputasi dapat bersifat nondeterministik.

Model terbaik dari masing-masing skenario disimpan berdasarkan nilai *validation loss* untuk digunakan pada tahap evaluasi. Kedua model kemudian diuji menggunakan dataset pengujian yang sama agar perbandingan kinerja dapat dilakukan secara adil. Hasil evaluasi digunakan untuk menentukan konfigurasi model yang memberikan kinerja terbaik dalam mengklasifikasikan citra ke dalam kelas anorganik, bukan sampah, dan organik.

2.6. Evaluasi Model

Evaluasi model dilakukan menggunakan 1.298 citra pada data pengujian yang tidak digunakan selama proses pelatihan maupun validasi. Data pengujian terdiri atas 596 citra anorganik, 124 citra bukan sampah, dan 578 citra organik. Distribusi tersebut menunjukkan bahwa jumlah citra pada kelas bukan sampah lebih sedikit dibandingkan dua kelas lainnya. Oleh karena itu, evaluasi tidak hanya menggunakan akurasi keseluruhan, tetapi juga memperhatikan nilai *precision*, *recall*, dan *F1-score* pada setiap kelas serta nilai rata-rata *macro*. Penggunaan metrik tersebut bertujuan memberikan gambaran kinerja model yang lebih menyeluruh, khususnya dalam mengenali kelas dengan jumlah data yang lebih sedikit.

Metrik evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data pengujian. *Precision* menunjukkan ketepatan model ketika memprediksi suatu kelas, sedangkan *recall* mengukur kemampuan model dalam mengenali seluruh data yang benar-benar termasuk ke dalam kelas tersebut. Adapun *F1-score* merupakan rata-rata harmonis antara *precision* dan *recall*.

a. Accuracy

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

$$Accuracy = \frac{\text{Jumlah prediksi benar}}{\text{Jumlah seluruh data}} \times 100\%$$

Accuracy digunakan untuk mengukur perbandingan jumlah prediksi yang benar terhadap seluruh data pengujian. Rumus *accuracy* untuk klasifikasi multikelas adalah:

b. Precision

$$Precision_i = \frac{TP_i}{TP_i + FP_i}$$

Precision digunakan untuk mengukur ketepatan model ketika memprediksi suatu kelas. Perhitungan dilakukan untuk setiap kelas menggunakan pendekatan *one-versus-rest*:

c. Recall

$$Recall_i = \frac{TP_i}{TP_i + FN_i}$$

Recall digunakan untuk mengukur kemampuan model dalam mengenali seluruh data yang benar-benar termasuk ke dalam suatu kelas:

d. F1-Score

$$F1_i = 2 \times \frac{Precision_i \times Recall_i}{Precision_i + Recall_i}$$

F1-score merupakan nilai rata-rata harmonis antara *precision* dan *recall*:

Keterangan:

- (TP_i) (*True Positive*) merupakan jumlah data kelas ke-(i) yang diprediksi dengan benar.
- (FP_i) (*False Positive*) merupakan jumlah data dari kelas lain yang salah diprediksi sebagai kelas ke-(i).
- (FN_i) (*False Negative*) merupakan jumlah data kelas ke-(i) yang salah diprediksi sebagai kelas lain.

Untuk memperoleh gambaran kinerja model secara seimbang pada seluruh kategori, penelitian ini juga menggunakan rata-rata *macro*. Perhitungan *macro* dilakukan dengan memberikan bobot yang sama kepada setiap kelas tanpa mempertimbangkan jumlah data pada masing-masing kelas.

e. Macro Precision

$$Macro\ Precision = \frac{1}{C}\sum_{i=1}^{C} P\,recision_i$$

Macro Precision digunakan untuk menghitung rata-rata nilai *precision* dari seluruh kelas. Rumusnya adalah:

f. Macro Recall

$$Macro\ Recall = \frac{1}{C}\sum_{i=1}^{C} R\,ecall_i$$

Macro Recall digunakan untuk menghitung rata-rata nilai *recall* dari seluruh kelas. Rumusnya adalah:

g. Macro F1-Score

$$Macro\ F1 = \frac{1}{C}\sum_{i=1}^{C} F\,1_i$$

Macro F1-Score digunakan untuk menghitung rata-rata nilai *F1-score* dari seluruh kelas. Rumusnya adalah:

Keterangan:

- (P_i) merupakan nilai *precision* pada kelas ke-(i).
- (R_i) merupakan nilai *recall* pada kelas ke-(i).
- (F1_i) merupakan nilai *F1-score* pada kelas ke-(i).
- (C) merupakan jumlah seluruh kelas, yaitu tiga kelas.

Selain menggunakan metrik tersebut, evaluasi juga dilakukan dengan *confusion matrix* untuk mengetahui jumlah prediksi benar dan kesalahan klasifikasi pada setiap kategori. Hasil evaluasi per kelas digunakan untuk menganalisis kemampuan model dalam mengenali sampah anorganik, objek

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

bukan sampah, dan sampah organik. Analisis per kelas menjadi penting karena kategori bukan sampah memiliki jumlah data pengujian yang lebih sedikit dibandingkan dua kategori lainnya.

Tabel 4. Hasil Evaluasi Model Berdasarkan Kelas.

Kelas	Jumlah Data	Metrik	Feature Extraction	Fine-Tuning
Anorganik	596	Precision	91,03%	94,54%
		Recall	91,95%	92,95%
		F1-score	91,49%	93,74%
Bukan Sampah	124	Precision	82,98%	91,54%
		Recall	94,35%	95,97%
		F1-score	88,30%	93,70%
Organik	578	Precision	93,69%	93,47%
		Recall	89,97%	94,12%
		F1-score	82,93%	71,49%

Berdasarkan Tabel 5, model *Fine-Tuning* menunjukkan peningkatan kinerja pada sebagian besar metrik setiap kelas dibandingkan *Feature Extraction*. Pada kelas anorganik, nilai *F1-score* meningkat dari 91,49% menjadi 93,74%. Pada kelas bukan sampah, nilai *F1-score* meningkat dari 88,30% menjadi 93,70%. Sementara itu, pada kelas organik, nilai *F1-score* meningkat dari 91,79% menjadi 93,79%.

Perhatian khusus diberikan pada kelas bukan sampah karena jumlah data pengujiannya hanya 124 citra, lebih sedikit dibandingkan kelas anorganik sebanyak 596 citra dan organik sebanyak 578 citra. Model *Fine-Tuning* memperoleh *precision* sebesar 91,54% dan *recall* sebesar 95,97% pada kelas tersebut. Hasil ini menunjukkan bahwa model mampu mengenali sebagian besar citra bukan sampah sekaligus mempertahankan ketepatan prediksi yang baik. Dengan demikian, hasil evaluasi per kelas menunjukkan bahwa penerapan *Fine-Tuning* tidak hanya meningkatkan kinerja pada kelas dengan jumlah data lebih banyak, tetapi juga memberikan peningkatan pada kelas bukan sampah.

Tabel 5. Perbandingan Hasil Evaluasi Keseluruhan Model

Metrik	Feature Extraction	Fine-Tuning
Accuracy	91,29%	93,76%
Macro Precision	89,23%	93,18%
Macro Recall	92,09%	94,35%
Macro F1-score	90,53%	93,74%
Weighted F1-score	91,32%	93,76%

Berdasarkan Tabel 5, model *Fine-Tuning* memperoleh nilai *accuracy* sebesar 93,76%, lebih tinggi dibandingkan model *Feature Extraction* sebesar 91,29%. Peningkatan juga terlihat pada nilai *macro precision*, *macro recall*, dan *macro F1-score*. Nilai *macro F1-score* meningkat dari 90,53% menjadi 93,74%. Hasil tersebut menunjukkan bahwa model *Fine-Tuning* memberikan kinerja yang lebih baik dan lebih seimbang pada ketiga kelas dibandingkan skenario *Feature Extraction*. Oleh karena itu, model *Fine-Tuning* dipilih sebagai model akhir EcoVision AI.

Pengujian pada penelitian ini menggunakan satu pembagian dataset dengan *random seed* 42. Kedua skenario pelatihan, yaitu *Feature Extraction* dan *Fine-Tuning*, dievaluasi menggunakan data pengujian yang sama sehingga hasil keduanya dapat dibandingkan secara langsung. Pengujian berulang menggunakan beberapa nilai *random seed* belum dilakukan. Oleh karena itu, hasil evaluasi dilaporkan berdasarkan satu pelaksanaan eksperimen dan tidak disajikan dalam bentuk rata-rata maupun simpangan baku dari beberapa pengujian. Kondisi ini menjadi keterbatasan penelitian karena variasi hasil akibat perubahan pembagian dataset maupun inisialisasi proses pelatihan belum dianalisis. Pengujian menggunakan beberapa *random seed* dapat dilakukan pada penelitian selanjutnya untuk mengetahui konsistensi kinerja model.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

3. HASIL DAN PEMBAHASAN

3.1. Hasil Evaluasi Model

Evaluasi model dilakukan untuk mengetahui kemampuan arsitektur MobileNetV2 dalam mengklasifikasikan citra ke dalam tiga kategori, yaitu organik, anorganik, dan bukan sampah. Pengujian menggunakan 1.298 citra yang tidak dilibatkan dalam proses pelatihan maupun validasi. Data pengujian terdiri atas 596 citra anorganik, 124 citra bukan sampah, dan 578 citra organik. Dua skenario pelatihan dibandingkan, yaitu *Feature Extraction* (seluruh lapisan dasar MobileNetV2 dibekukan) dan *Fine-Tuning* (19 lapisan terakhir pada *backbone* dilatih kembali, dengan lapisan *Batch Normalization* tetap dibekukan).

Hasil evaluasi menunjukkan bahwa skenario *Feature Extraction* memperoleh akurasi sebesar 91,29%, sedangkan *Fine-Tuning* memperoleh akurasi sebesar 93,76%. Untuk memberikan gambaran yang lebih menyeluruh, evaluasi juga mempertimbangkan nilai *precision*, *recall*, dan *F1-score* pada setiap kategori. Hasil perbandingan kedua skenario disajikan dalam satu tabel agar kinerja masing-masing kategori dapat diamati secara langsung.

Tabel 6. Hasil Evaluasi Model Berdasarkan Kategori

Skenario	Kategori	Support	Precision	Recall	F1-score
Feature Extraction	Anorganik	596	91,03%	91,95%	91,49%
Feature Extraction	Bukan sampah	124	82,98%	94,35%	88,30%
Feature Extraction	Organik	578	93,69%	89,97%	91,79%
Fine-Tuning	Anorganik	596	94,54%	92,95%	93,74%
Fine-Tuning	Bukan sampah	124	91,54%	95,97%	93,70%
Fine-Tuning	Organik	578	93,47%	94,12%	93,79%

Tabel 7. Perbandingan Kinerja Model Secara Keseluruhan

Metrik	Feature Extraction	Fine-Tuning
Accuracy	91,29%	93,76%
Macro Precision	89,23%	93,18%
Macro Recall	92,09%	94,35%
Macro F1-score	90,53%	93,74%
Weighted F1-score	91,32%	93,76%

Berdasarkan hasil tersebut, *Fine-Tuning* menunjukkan kinerja yang lebih baik dibandingkan *Feature Extraction* pada seluruh metrik evaluasi secara keseluruhan. Peningkatan ini juga terlihat pada nilai *F1-score* setiap kategori. Meskipun demikian, evaluasi per kategori tetap diperlukan karena jumlah citra pada kelas bukan sampah lebih sedikit dibandingkan dua kelas lainnya.

Pada skenario *Feature Extraction*, kategori bukan sampah memperoleh *precision* sebesar 82,98%, lebih rendah dibandingkan kategori anorganik sebesar 91,03% dan organik sebesar 93,69%. Nilai tersebut menunjukkan bahwa sebagian citra yang diprediksi sebagai bukan sampah sebenarnya termasuk ke dalam kategori organik atau anorganik. Kondisi ini dapat terjadi karena objek bukan sampah memiliki variasi bentuk, warna, dan karakteristik visual yang beragam. Selain itu, beberapa objek bukan sampah dapat memiliki kemiripan visual dengan sampah, sehingga model berpotensi mengalami kesulitan dalam membedakan keduanya. Jumlah data bukan sampah yang lebih sedikit juga dapat membatasi keragaman contoh yang dipelajari model, meskipun penelitian ini telah menerapkan *class weight* untuk membantu mengatasi ketidakseimbangan jumlah data.

Pada skenario *Fine-Tuning*, nilai *precision* kategori bukan sampah meningkat menjadi 91,54%, dengan *recall* sebesar 95,97% dan *F1-score* sebesar 93,70%. Hasil ini menunjukkan bahwa proses *Fine-Tuning* membantu meningkatkan kemampuan model dalam mengenali kategori bukan sampah sekaligus mengurangi prediksi keliru terhadap kategori tersebut. Namun, nilai *precision* kategori bukan sampah masih sedikit lebih rendah dibandingkan kategori anorganik dan organik. Hal ini

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

menunjukkan bahwa membedakan objek bukan sampah dari objek sampah masih menjadi tantangan dalam proses klasifikasi.

Perbedaan jenis kesalahan klasifikasi juga memiliki konsekuensi terhadap penggunaan aplikasi EcoVision AI. Apabila citra sampah organik atau anorganik diprediksi sebagai bukan sampah, objek tersebut berpotensi tidak dikenali sebagai sampah sehingga pengguna tidak memperoleh arahan pemilahan yang sesuai. Kesalahan ini dapat menghambat proses pemilahan karena sampah yang seharusnya dikelola justru dianggap bukan sampah. Sebaliknya, apabila objek bukan sampah diprediksi sebagai sampah, aplikasi dapat memberikan informasi kategori organik atau anorganik yang tidak sesuai sehingga berpotensi membingungkan pengguna. Sementara itu, kesalahan klasifikasi antara organik dan anorganik dapat menyebabkan sampah ditempatkan pada kelompok pemilahan yang keliru.

Berdasarkan hasil pengujian, skenario *Fine-Tuning* dipilih sebagai model akhir karena memperoleh akurasi, *macro precision*, *macro recall*, dan *macro F1-score* yang lebih tinggi dibandingkan *Feature Extraction*. Selain itu, nilai *F1-score* pada ketiga kategori juga menunjukkan hasil yang relatif seimbang. Walaupun demikian, hasil evaluasi tetap menunjukkan bahwa model belum sepenuhnya bebas dari kesalahan klasifikasi. Oleh karena itu, hasil prediksi aplikasi perlu dipahami sebagai bantuan dalam proses identifikasi awal, bukan sebagai pengganti pemeriksaan langsung terhadap objek sampah.

Model *Fine-Tuning* selanjutnya diimplementasikan ke dalam aplikasi EcoVision AI berbasis web menggunakan Flask. Aplikasi menyediakan antarmuka untuk mengunggah citra dan menampilkan hasil prediksi kategori berdasarkan model yang telah dilatih. Dengan demikian, hasil penelitian tidak hanya menunjukkan kinerja model melalui pengujian kuantitatif, tetapi juga penerapannya dalam bentuk aplikasi klasifikasi citra sampah.

3.2. Analisis Confusion Matrix

Confusion matrix digunakan untuk menganalisis kemampuan model dalam mengklasifikasikan citra ke dalam tiga kategori, yaitu anorganik, bukan sampah, dan organik. Analisis dilakukan dengan membandingkan label sebenarnya dengan hasil prediksi model sehingga dapat diketahui jumlah prediksi yang benar maupun kesalahan klasifikasi pada setiap kelas. Dalam penelitian ini, analisis dilakukan terhadap dua skenario model, yaitu *Feature Extraction* dan *Fine-Tuning*, menggunakan data pengujian yang sama sebanyak 1.298 citra.

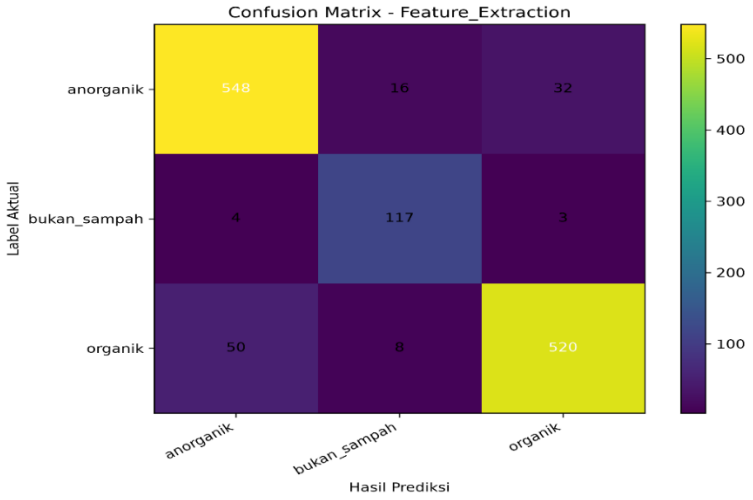

Gambar 3. Confusion Matrix Model Feature Extraction

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

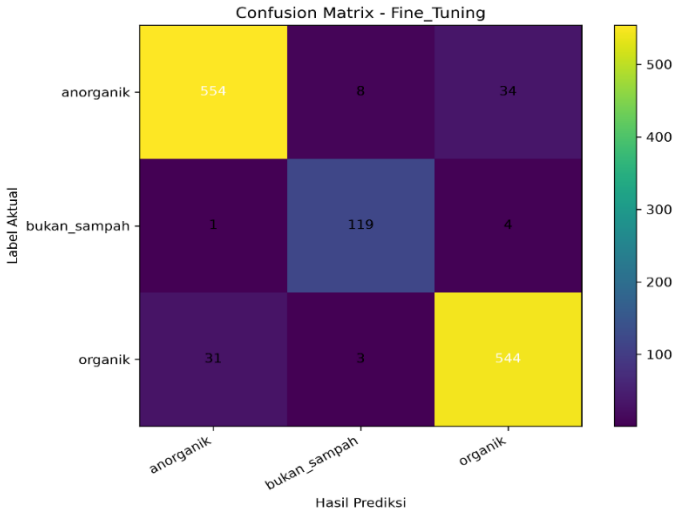

Gambar 4. Confusion Matrix Model Fine-Tuning

Berdasarkan hasil *confusion matrix*, model *Feature Extraction* berhasil mengklasifikasikan 1.185 citra dengan benar dan menghasilkan 113 kesalahan klasifikasi. Sementara itu, model *Fine-Tuning* berhasil mengklasifikasikan 1.217 citra dengan benar dan menghasilkan 81 kesalahan klasifikasi. Hasil tersebut menunjukkan bahwa proses *Fine-Tuning* mampu meningkatkan jumlah prediksi benar sebanyak 32 citra dibandingkan model *Feature Extraction*.

Pada model *Fine-Tuning*, kesalahan klasifikasi paling banyak terjadi antara kategori anorganik dan organik. Sebanyak 34 citra anorganik diprediksi sebagai organik, sedangkan 31 citra organik diprediksi sebagai anorganik. Selain itu, terdapat 8 citra anorganik dan 3 citra organik yang diprediksi sebagai bukan sampah. Sebaliknya, terdapat 4 citra bukan sampah yang diprediksi sebagai organik dan 1 citra bukan sampah yang diprediksi sebagai anorganik. Dengan demikian, sebagian besar kesalahan klasifikasi terjadi pada proses pembedaan antara sampah organik dan anorganik.

Kesalahan dalam mengklasifikasikan sampah sebagai bukan sampah perlu diperhatikan dalam penerapan EcoVision AI karena dapat menyebabkan objek yang seharusnya dipilah tidak teridentifikasi sebagai sampah. Sebaliknya, kesalahan dalam mengklasifikasikan objek bukan sampah sebagai sampah dapat menghasilkan rekomendasi pemilahan yang tidak sesuai. Oleh karena itu, evaluasi kemampuan model perlu mempertimbangkan pola kesalahan pada setiap kategori, bukan hanya jumlah prediksi yang benar.

Salah satu contoh kesalahan prediksi ditunjukkan pada Gambar 5. Citra dengan label sebenarnya anorganik tersebut diprediksi sebagai organik dengan nilai *confidence* sebesar 99,9984%. Berdasarkan pengamatan visual, citra menampilkan beberapa objek dengan bentuk dan karakteristik permukaan yang berbeda, termasuk objek dengan tekstur kasar dan berserat. Karakteristik visual tersebut diduga menjadi salah satu aspek yang memengaruhi proses pengenalan fitur oleh model. Namun, pengamatan ini belum cukup untuk memastikan bahwa tekstur merupakan penyebab langsung kesalahan klasifikasi.



Gambar 5. Contoh Kesalahan Prediksi Citra Anorganik yang Diklasifikasikan sebagai Organik

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

Tabel 8. Contoh Kesalahan Prediksi Model Fine-Tuning

No.	Nama Citra	Label Sebenarnya	Label Prediksi	Confidence
1	anorganik_02240_00354.jpg	Anorganik	Organik	99,9984%
2	organik_00106_00165.jpg	Organik	Anorganik	99,9948%
3	anorganik_01686_00299.jpg	Anorganik	Bukan sampah	94,6967%
4	organik_01028_00267.jpg	Organik	Bukan sampah	93,7259%
5	bukan_sampah_00047_00011.jpg	Bukan sampah	Organik	93,1564%
6	bukan_sampah_00754_00110.jpg	Bukan sampah	Anorganik	44,3854%

Berdasarkan Tabel 8, kesalahan prediksi model Fine-Tuning terjadi pada ketiga kategori klasifikasi. Kesalahan yang paling terlihat adalah tertukarnya kategori anorganik dan organik. Selain itu, terdapat citra sampah yang diklasifikasikan sebagai bukan sampah serta citra bukan sampah yang diklasifikasikan sebagai sampah. Beberapa kesalahan juga menunjukkan nilai confidence yang tinggi, seperti prediksi citra anorganik sebagai organik sebesar 99,9984%. Hal ini menunjukkan bahwa tingkat keyakinan model tidak selalu menjamin ketepatan hasil klasifikasi.

Selain karakteristik bentuk dan tekstur, pencahayaan, sudut pengambilan gambar, serta kualitas citra juga berpotensi memengaruhi hasil klasifikasi. Akan tetapi, faktor-faktor tersebut belum diuji secara khusus dalam penelitian ini sehingga tidak dapat dinyatakan sebagai penyebab pasti kesalahan prediksi. Hasil analisis ini menunjukkan bahwa meskipun model *Fine-Tuning* menghasilkan kinerja lebih baik, model masih memiliki keterbatasan dalam membedakan karakteristik visual beberapa kategori sampah.

3.3. Implementasi Aplikasi EcoVision AI

Model klasifikasi yang telah dilatih kemudian diimplementasikan ke dalam aplikasi berbasis web bernama EcoVision AI menggunakan framework Flask. Implementasi ini bertujuan agar model tidak hanya digunakan untuk pengujian secara teknis, tetapi juga dapat dimanfaatkan melalui antarmuka yang memudahkan pengguna dalam melakukan klasifikasi citra sampah. Model yang digunakan dalam aplikasi merupakan model MobileNetV2 hasil proses Fine-Tuning karena menghasilkan kinerja evaluasi yang lebih baik dibandingkan skenario Feature Extraction.

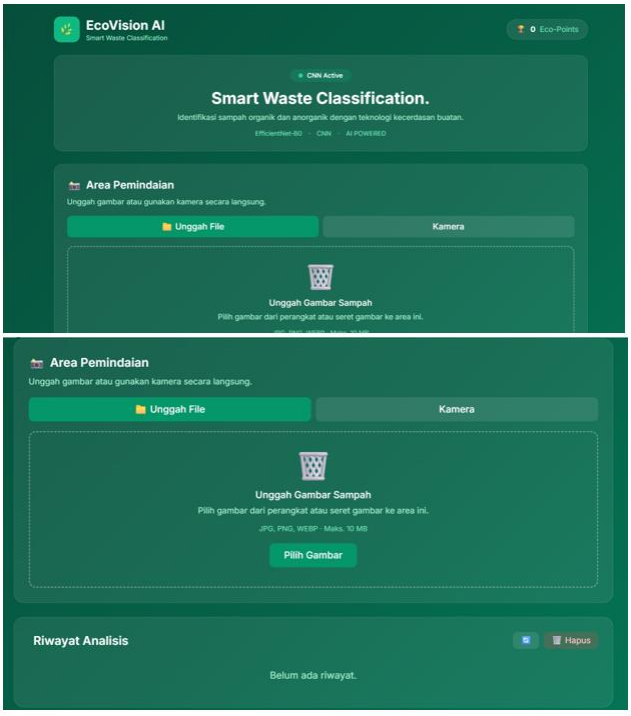

Gambar 6. Rancangan Antarmuka Pengguna Aplikasi EcoVision AI

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

Gambar 6 menunjukkan rancangan antarmuka pengguna aplikasi EcoVision AI yang terdiri atas beberapa tampilan utama. Halaman utama menyediakan fasilitas untuk mengunggah gambar yang akan diklasifikasikan. Halaman hasil prediksi menampilkan kategori sampah beserta nilai confidence dan probabilitas setiap kelas. Selain itu, terdapat tampilan proses klasifikasi yang menggambarkan tahapan preprocessing dan inference menggunakan model MobileNetV2. Aplikasi juga menyediakan tampilan pesan kesalahan untuk memberikan informasi apabila gambar yang diunggah tidak memenuhi ketentuan. Rancangan antarmuka memperhatikan responsivitas agar aplikasi dapat digunakan melalui perangkat desktop maupun perangkat mobile.

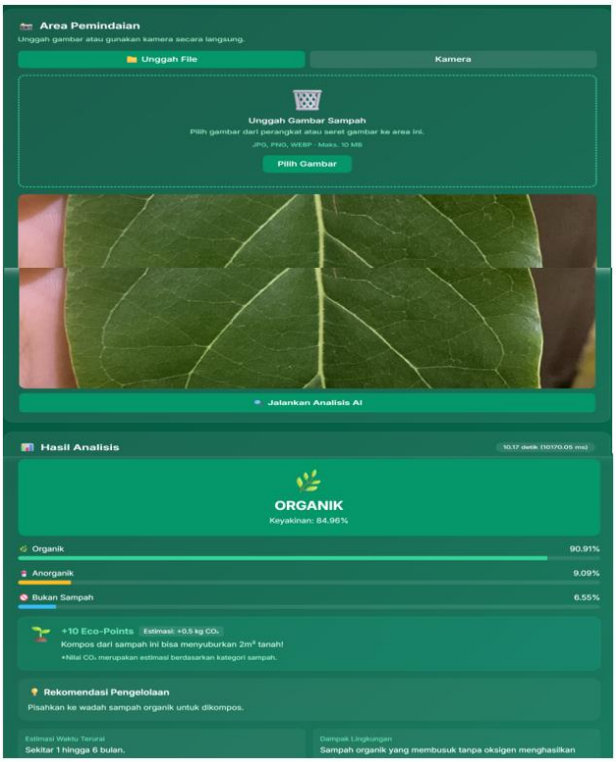

Gambar 7. Tampilan Hasil Analisis Aplikasi EcoVision AI

Gambar 7 memperlihatkan contoh hasil analisis citra yang diklasifikasikan sebagai Organik dengan nilai *confidence* (keyakinan) sebesar 84.96%. Aplikasi juga menampilkan probabilitas setiap kategori (Organik 90.91%, Anorganik 9.09%, dan Bukan Sampah 6.55%), informasi Eco-Points (+10 Eco-Points), estimasi penghematan CO_2 (Estimasi: +0.5 kg CO_2), serta rekomendasi pengelolaan sampah (Pisahkan ke wadah sampah organik untuk dikompos). Informasi tersebut disajikan untuk membantu pengguna memahami hasil klasifikasi dan tindakan pengelolaan yang dapat dilakukan. Nilai Eco-Points dan estimasi penghematan CO_2 merupakan informasi pendukung yang bersifat ilustratif berdasarkan aturan perhitungan pada aplikasi, bukan hasil pengukuran emisi secara langsung. Oleh karena itu, nilai tersebut tidak dapat diartikan sebagai jumlah emisi CO_2 yang benar-andap berhasil dikurangi.

Selain proses klasifikasi, aplikasi menyediakan fitur riwayat analisis yang disimpan menggunakan SQLite berdasarkan sesi pengguna. Pengguna dapat melihat riwayat hasil klasifikasi, menghapus data tertentu, maupun menghapus seluruh riwayat. Aplikasi juga menyediakan fitur pengunduhan hasil analisis dalam bentuk gambar dan fitur berbagi informasi hasil klasifikasi.

Pengujian aplikasi dilakukan untuk memeriksa fungsi utama dan kesesuaian hasil prediksi dengan model yang digunakan. Pengujian mencakup proses unggah citra, pelaksanaan klasifikasi, penampilan hasil prediksi, penanganan input tidak valid, serta konsistensi hasil prediksi. Pengujian konsistensi dilakukan dengan membandingkan hasil prediksi aplikasi dengan hasil prediksi model menggunakan citra pengujian yang sama. Sementara itu, pengujian input tidak valid dilakukan terhadap berkas

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

dengan format yang tidak didukung, berkas kosong, dan berkas yang tidak dapat dibaca sebagai gambar. Hasil pengujian fungsi aplikasi didokumentasikan berdasarkan skenario pengujian tersebut.

Berdasarkan hasil evaluasi terhadap 1.298 citra pada dataset pengujian, model Fine-Tuning memperoleh accuracy sebesar 93,76%, macro precision sebesar 93,18%, macro recall sebesar 94,35%, dan macro F1-score sebesar 93,74%. Waktu inferensi rata-rata model pada lingkungan pengujian adalah 62,752 milidetik per citra. Nilai tersebut menunjukkan waktu pemrosesan inferensi model dan tidak mencakup keseluruhan waktu respons aplikasi web. Dengan demikian, model MobileNetV2 hasil Fine-Tuning telah diintegrasikan ke dalam aplikasi EcoVision AI untuk mendukung klasifikasi citra sampah melalui antarmuka berbasis web.

4. KESIMPULAN

Penelitian ini menghasilkan aplikasi EcoVision AI untuk klasifikasi citra sampah ke dalam tiga kategori, yaitu organik, anorganik, dan bukan sampah, menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2. Model dikembangkan menggunakan pendekatan transfer learning melalui dua tahap, yaitu Feature Extraction dan Fine-Tuning, kemudian diintegrasikan ke dalam aplikasi web berbasis Flask. Berdasarkan hasil pengujian terhadap 1.298 citra pada dataset test, model Fine-Tuning memperoleh accuracy sebesar 93,76%, macro precision sebesar 93,18%, macro recall sebesar 94,35%, dan macro F1-score sebesar 93,74%. Hasil tersebut menunjukkan bahwa model mampu membedakan ketiga kategori dengan kinerja yang baik pada dataset pengujian yang digunakan. Dengan demikian, klasifikasi tiga kategori memungkinkan aplikasi tidak hanya mengenali sampah organik dan anorganik, tetapi juga membedakan citra yang termasuk kategori bukan sampah.

Hasil analisis confusion matrix menunjukkan bahwa model masih menghasilkan 81 kesalahan klasifikasi dari 1.298 citra pengujian. Kesalahan paling banyak terjadi pada pertukaran kategori organik dan anorganik, yaitu sebanyak 65 citra. Sementara itu, pada kategori bukan sampah, model memperoleh recall sebesar 95,97% dengan lima citra yang salah diklasifikasikan. Temuan tersebut menunjukkan bahwa meskipun model telah memperoleh hasil evaluasi yang baik, pembedaan karakteristik visual antara sampah organik dan anorganik masih menjadi tantangan. Hasil penelitian ini terbatas pada dataset pengujian yang digunakan sehingga belum dapat dijadikan dasar untuk menyatakan bahwa model akan memperoleh performa yang sama pada kondisi lingkungan nyata. Oleh karena itu, pengujian eksternal menggunakan dataset independen dan citra yang diperoleh langsung dari lingkungan nyata masih diperlukan.

Penelitian selanjutnya disarankan untuk melakukan pengujian menggunakan dataset independen dengan variasi pencahayaan, sudut pengambilan gambar, latar belakang, dan kondisi objek yang lebih beragam. Selain itu, diperlukan analisis kesalahan yang lebih mendalam, khususnya terhadap kategori bukan sampah, untuk mengetahui kemungkinan kesalahan pengenalan antara objek sampah dan objek non-sampah. Pengembangan berikutnya juga dapat dilakukan melalui evaluasi strategi Fine-Tuning, penyesuaian parameter pelatihan, serta perbandingan dengan arsitektur CNN lainnya. Dengan pengembangan dan pengujian lanjutan tersebut, EcoVision AI diharapkan dapat menjadi sistem pendukung identifikasi dan pemilahan sampah yang lebih andal ketika diterapkan pada kondisi penggunaan nyata.

PERNYATAAN KONTRIBUSI PENULIS (CREDIT)

Jubel K Aritonang: Penulisan – peninjauan dan penyuntingan, Penulisan – draf awal, Validasi, Perangkat lunak, Metodologi, Konseptualisasi. **Jenly Imuly**: Penulisan – draf awal, Analisis formal, Kurasi data, Konseptualisasi. **Adit Maulana Ardiansyah**: Penulisan – draf awal, Perangkat lunak, Investigasi. **Rachmat Adi Purnama**: Penulisan – peninjauan dan penyuntingan, Supervisi. **Veti Apriana**: Penulisan – peninjauan dan penyuntingan, Supervisi. **Sujiliani Heristian**: Penulisan – peninjauan dan penyuntingan, Supervisi.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.455
Page 883-901

PERNYATAAN KONFLIK KEPENTINGAN

Para penulis menyatakan bahwa tidak terdapat kepentingan finansial atau hubungan pribadi yang diketahui yang dapat memengaruhi hasil penelitian yang dilaporkan dalam artikel ini.

PERNYATAAN PENDANAAN

Penulis tidak menerima dukungan finansial untuk penelitian, kepenulisan, dan/atau publikasi artikel ini.

PERNYATAAN PENGGUNAAN AI GENERATIF DAN TEKNOLOGI BERBANTUAN AI DALAM PROSES PENULISAN

Para penulis menggunakan Generative AI untuk meningkatkan kejelasan penulisan artikel ini. Seluruh konten yang dibantu oleh AI telah ditinjau dan disunting oleh penulis, dan para penulis bertanggung jawab sepenuhnya atas isi akhir yang dipublikasikan.

REFERENCES

[1] M. I. B. Ahmed *et al.*, "Deep Learning Approach to Recyclable Products Classification: Towards Sustainable Waste Management," *Sustainability*, vol. 15, no. 14, p. 11138, Jul. 2023, doi: 10.3390/su151411138.

[2] M. E. Purba, A. Z. Situmorang, G. L. Br Ginting, M. W. P. Lubis, and F. M. Sinaga, "Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN," *J. Sifo Mikroskil*, vol. 26, no. 1, pp. 37–54, Apr. 2025, doi: 10.55601/jsm.v26i1.1510.

[3] A. Cardila and D. Lasut, "Klasifikasi jenis sampah organik dan anorganik berbasis citra menggunakan convolutional neural network," pp. 345–351, 2026.

[4] B. Bernmarc Bungtilu Pallo, F. Yusuf Bisilisin, and S. Juszandri Bulan, "IMPLEMENTASI COMPUTER VISION UNTUK KLASIFIKASI JENIS SAMPAH ORGANIK DAN NON-ORGANIK MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 10, no. 5, pp. 7601–7608, Sep. 2026, doi: 10.36040/jati.v10i5.19142.

[5] Doly Ilham Saputra Huta Julu and Dewi Nurdiyah, "KLASIFIKASI SAMPAH ORGANIK DAN NON ORGANIK MENGGUNAKAN TRANSFER LEARNING," *J. Transform.*, vol. 23, no. 1, pp. 12–29, Jul. 2025, doi: 10.26623/transformatika.v23i1.12201.

[6] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.

[7] F. Gurcan and A. Soylu, "Automated waste classification for smart recycling: A multi-class CNN approach with transfer learning and pre-trained models," *Environ. Technol. Innov.*, vol. 41, p. 104673, Mar. 2026, doi: 10.1016/j.eti.2025.104673.

[8] Q. Zhang, Q. Yang, X. Zhang, Q. Bao, J. Su, and X. Liu, "Waste image classification based on transfer learning and convolutional neural network," *Waste Manag.*, vol. 135, pp. 150–157, Nov. 2021, doi: 10.1016/j.wasman.2021.08.038.

[9] H. Abdu and M. H. Mohd Noor, "A Survey on Waste Detection and Classification Using Deep Learning," *IEEE Access*, vol. 10, pp. 128151–128165, 2022, doi: 10.1109/ACCESS.2022.3226682.

[10] F. Mubaraq and C. Fadhillah, "Klasifikasi Multikelas Sampah Menggunakan CNN Dengan Arsitektur," vol. V, no. 2, 2026.

[11] D. Aghellar and A. S. Sunge, "the Comparative Analysis and Optimization of CNN and MobileNetV2 Using Data Augmentation and Fine-Tuning for Waste Classification," *Ultim. J. Tek. Inform.*, vol. 18, no. 1, pp. 118–126, Jun. 2026, doi: 10.31937/ti.v18i1.4687.

[12] J. Yang, K. Zhou, Y. Li, and Z. Liu, "Generalized Out-of-Distribution Detection: A Survey," *Int. J. Comput. Vis.*, vol. 132, no. 12, pp. 5635–5662, Dec. 2024, doi: 10.1007/s11263-024-02117-4.

[13] H. Wang, S. Vaze, and K. Han, "Dissecting Out-of-Distribution Detection and Open-Set Recognition: A Critical Analysis of Methods and Benchmarks," *Int. J. Comput. Vis.*, vol. 133, no. 3, pp. 1326–1351, Mar. 2025, doi: 10.1007/s11263-024-02222-4.

[14] L. Yong, L. Ma, D. Sun, and L. Du, "Application of MobileNetV2 to waste classification," *PLoS One*, vol. 18, no. 3 March, pp. 1–16, 2023, doi: 10.1371/journal.pone.0282336.

[15] M. Chhabra, B. Sharan, M. Elbarachi, and M. Kumar, "Intelligent waste classification approach based on improved multi-layered convolutional neural network," *Multimed. Tools Appl.*, vol. 83, no. 36, pp. 84095–84120, Apr. 2024, doi: 10.1007/s11042-024-18939-w.

[16] N. B. Nugraha and W. Windini, "Performance Analysis of MobileNetV2 for Five-Category Waste Image

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Classification Using Transfer Learning," *J. Appl. Informatics Comput.*, vol. 10, no. 5, pp. 4396–4403, Oct. 2026, doi: 10.30871/jaic.v10i5.13771.

[17] I Gede Agus Perdana Putra and Md. Wira Putra Dananjaya, "Pengembangan Website Klasifikasi Jenis Sampah pada Anak menggunakan Metode CNN dengan Arsitektur MobileNetV2," *J. Publ. Sist. Inf. dan Manaj. Bisnis*, vol. 5, no. 3, pp. 304–316, Sep. 2026, doi: 10.55606/jupsim.v5i3.8012.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/