

# Penerapan Arsitektur Deep Learning EfficientNetB0 Berbasis Citra Digital untuk Meningkatkan Kinerja Sistem Klasifikasi Sampah Organik, Anorganik, dan B3

Anggita Alya Salsabila, Muljono \*

Fakultas Ilmu Komputer, Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: [1111202214401@mhs.dinus.ac.id](mailto:1111202214401@mhs.dinus.ac.id), [2.\\*muljono@dsn.dinus.ac.id](mailto:muljono@dsn.dinus.ac.id)

Email Penulis Korespondensi: [muljono@dsn.dinus.ac.id](mailto:muljono@dsn.dinus.ac.id)

Submitted **01-12-2025**; Accepted **30-12-2025**; Published **31-12-2025**

## Abstrak

Pengelolaan sampah di Indonesia masih menjadi tantangan besar akibat volume sampah yang meningkat dan rendahnya efisiensi proses pemilahan secara manual di Tempat Pembuangan Akhir (TPA). Penelitian ini bertujuan untuk meningkatkan kinerja sistem klasifikasi sampah otomatis untuk tiga kategori: organik, anorganik, dan bahan berbahaya dan beracun (B3) menggunakan teknologi *computer vision* berbasis *deep learning*. Metode yang diusulkan adalah arsitektur EfficientNetB0 dengan pendekatan *transfer learning*, yang kinerjanya akan dibandingkan dengan empat arsitektur *pre-trained* lain (VGG-16, InceptionV3, MobileNetV2, dan ResNet50). Dataset yang digunakan berjumlah 7.003 citra valid yang sudah dikumpulkan dari sumber publik dan pengambilan secara manual setelah proses pembersihan data. Dataset dibagi menjadi 70% sebagai data latih (*train*), 20% sebagai data validasi, dan 10% sebagai data uji (*test*). Strategi data *augmentation* dan *class balancing* digunakan untuk meningkatkan variasi dan mengatasi ketidakseimbangan data antar kelas. Pelatihan dilakukan dalam dua tahap: *Feature Extraction* dan *Fine-Tuning*, dengan *hyperparameter* yang konsisten untuk perbandingan yang adil. Evaluasi kinerja dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *f1-score*. Hasil pengujian menunjukkan bahwa EfficientNetB0 berhasil mencapai kinerja terbaik dengan tingkat akurasi 96.87%. Arsitektur modern seperti EfficientNetB0 telah terbukti mampu mengekstraksi fitur kompleks dengan efisiensi komputasi yang baik, sehingga berpotensi untuk digunakan dalam sistem pemilah sampah otomatis berbasis kecerdasan buatan untuk mendukung pengelolaan sampah yang lebih efektif dan berkelanjutan.

**Kata Kunci:** Klasifikasi sampah; *Deep learning*; CNN; *Transfer Learning*; EfficientNetB0; Sampah B3

## Abstract

Waste management in Indonesia remains a major challenge due to increasing waste volumes and the low efficiency of manual sorting processes at Landfills (TPA). This study aims to improve the performance of an automated waste classification system for three categories: organic, inorganic, and hazardous and toxic waste (B3) using deep learning-based computer vision technology. The proposed method is the EfficientNetB0 architecture with a transfer learning approach, whose performance is compared with four other pre-trained architectures (VGG-16, InceptionV3, MobileNetV2, and ResNet50). The dataset used consists of 7,003 valid images collected from public sources and manual acquisition after a data cleaning process. The dataset is divided into 70% as training data, 20% as validation data, and 10% as test data. Data augmentation and class balancing strategies are used to increase variation and overcome data imbalance between classes. Training is conducted in two stages: Feature Extraction and Fine-Tuning, with consistent hyperparameters for a fair comparison. Performance evaluation is performed using accuracy, precision, recall, and f1-score metrics. The test results show that EfficientNetB0 managed to achieve the best performance with an accuracy rate of 96.87%. Modern architectures like EfficientNetB0 have proven capable of extracting complex features with good computational efficiency, thereby holding the potential for use in AI-based automatic waste sorting systems to support more effective and sustainable waste management.

**Keywords:** Waste classification; Deep learning; CNN; Transfer learning; EfficientNetB0; Hazardous Waste

## 1. PENDAHULUAN

Volume limbah yang dihasilkan di Indonesia terus meningkat bersamaan dengan pertumbuhan penduduk dan perubahan pola konsumsi masyarakat [1], [2]. Peningkatan jumlah sampah yang tidak diimbangi dengan ketersediaan infrastruktur pengelolaan yang memadai adalah salah satu masalah lingkungan yang paling mendesak saat ini. Keterbatasan dalam pengelolaan limbah memunculkan berbagai masalah, mulai dari pencemaran lingkungan, penyebaran penyakit, dan dampak pada estetika perkotaan. Kegagalan dalam mengelola aliran sampah ini mengakibatkan hilangnya peluang ekonomi dari bahan yang bisa didaur ulang [3].

Aspek penting dari pengelolaan limbah adalah proses penyotiran. Penyotiran yang efisien di Tempat Pembuangan Akhir (TPA) atau fasilitas daur ulang adalah kunci untuk meningkatkan laju daur ulang bahan anorganik, memastikan penanganan limbah B3 yang aman, dan memudahkan pengomposan untuk bahan organik [4]. Namun, sebagian besar sistem pemilahan sampah di Indonesia saat ini masih menggunakan metode manual, yang memerlukan banyak waktu dan tenaga yang signifikan, dan juga memiliki tingkat kesalahan manusia (*human error*), menyebabkan kontaminasi pada aliran daur ulang, dan risiko kesehatan bagi pekerja [5]. Akibatnya, pengembangan sistem pemilahan limbah otomatis yang cepat dan tepat menjadi sangat mendesak untuk mengatasi hambatan ini [6], [7].

Teknologi *Computer Vision* yang didukung oleh *Deep Learning*, telah muncul sebagai solusi yang paling menjanjikan [8]. Khususnya, arsitektur *Convolutional Neural Network* (CNN), yang telah menunjukkan keberhasilan besar dalam klasifikasi gambar karena kemampuannya untuk mengekstraksi fitur visual secara otomatis dan hierarkis [9]. Berbagai penelitian telah menerapkan arsitektur CNN untuk mengklasifikasi sampah dengan berfokus pada model yang berbeda [10]. Beberapa penelitian awal telah menggunakan model dasar (*foundational models*) seperti *Visual Geometry*

Group (VGG), yang dikenal dengan arsitekturnya yang dalam dan seragam, berfungsi sebagai dasar yang kuat [11]. Namun, model-model awal biasanya memiliki banyak parameter dan membutuhkan biaya komputasi yang tinggi, yang membuatnya sulit untuk diterapkan dalam sistem komputasi *real-time* atau *edge computing* [12], [13].

Seiring perkembangan teknologi, fokus penelitian beralih ke arsitektur yang lebih ringan kerana tuntutan efisiensi yang meningkat [8]. Misalnya, model seperti MobileNetV2 telah dipelajari secara menyeluruh karena kemampuannya memberikan akurasi yang baik dengan biaya komputasi yang sangat rendah, yang membuatnya ideal untuk diimplementasikan pada perangkat *edge* atau sistem *real-time* [12], [14]. Meskipun demikian, model ini belum sepenuhnya mengoptimalkan *trade-off* antara akurasi dan efisiensi. Maka dari itu, arsitektur yang lebih baru seperti EfficientNetB0 mendapat perhatian khusus untuk mengikuti tren efisiensi ini. Keunggulan dari EfficientNetB0 terletak pada metode *compound scaling* nya, yang membedakannya dengan model yang hanya berfokus pada kelebihan (*depth*) atau lebar (*width*) jaringan. Teknik ini ditemukan sebagai metode terbaik untuk menyeimbangkan ketiga dimensi jaringan (kedalaman, lebar, dan resolusi input) secara bersamaan. Model ini dapat mencapai akurasi yang sangat tinggi dengan banyak parameter dan biaya komputasi yang jauh lebih rendah daripada arsitektur lain yang sebanding [13]. Efisiensi ini sangat penting untuk penerapan sistem klasifikasi yang membutuhkan kecepatan dan daya komputasi minimal di lingkungan industri [15], [16].

Model lain yang juga relevan untuk dipertimbangkan, seperti arsitektur InceptionV3 yang menggunakan pendekatan “modul inception” yang unik. Modul ini menerapkan filter konvolusi dengan berbagai ukuran (seperti 1x1, 3x3, dan 5x5) secara parallel dalam satu lapisan, yang memungkinkan untuk menangkap fitur visual dalam berbagai skala. Kemampuan ini terbukti efektif untuk tugas klasifikasi citra yang kompleks, seperti deteksi penyakit pada daun oleh Khairun Nisa et al, yang memiliki masalah yang mirip dengan variasi entuk, dan ukuran objek sampah [17]. Selain mengandalkan model *transfer learning* yang besar, arsitektur CNN kustom yang dirancang dari awal (*from scratch*) telah menunjukkan efektif oleh beberapa peneliti [2], [18]. Metode ini biasanya digunakan dengan tujuan membuat model yang lebih ringan dan spesifik untuk tugas tertentu. Seperti penelitian yang dilakukan oleh Muslihati et al, menciptakan CNN sederhana yang terdiri dari satu *dense layer* dan tiga lapisan konvolusi yang terbukti berhasil mencapai akurasi tinggi 96% untuk tugas klasifikasi biner (organik dan anorganik) [18]. Penelitian tersebut menunjukkan bahwa model kustom yang lebih ramping dibandingkan dengan arsitektur pre-trained yang kompleks dapat menjadi opsi yang layak untuk dataset dengan cangkupan yang lebih terfokus. Arsitektur ini penting dalam banyak hal. Menurut penelitian yang dilakukan Lestari et al, menemukan bahwa MobileNetV2 memiliki kemampuan untuk mengidentifikasi kadar kolesterol dalam darah [14]. Selain itu, penelitian oleh Elvitaria et al juga menggunakan ResNet50 dan EfficientNetB0 untuk klasifikasi telur cacing [15]. Kesuksesan metode *transfer learning* ini dalam bidang medis yang kompleks menunjukkan ketahanan (*robustness*) model potensinya untuk adaptasi *domain* yang sukses dengan tugas klasifikasi sampah [14], [15], [19].

Banyak penelitian yang hanya berfokus pada satu atau dua model arsitektur saja [8], [12], [13], sehingga sulit untuk menemukan model yang paling efektif secara objektif. Selain itu, analisis perbandingan juga dilakukan pada kumpulan data yang termasuk dalam kategori B3 yang berarti bahan berbahaya dan beracun. Dalam dataset penelitian publik, kategori B3 ini sering diabaikan meskipun sangat penting. Namun, kesalahan dalam klasifikasinya dapat menyebabkan kerusakan lingkungan yang signifikan [5], [20].

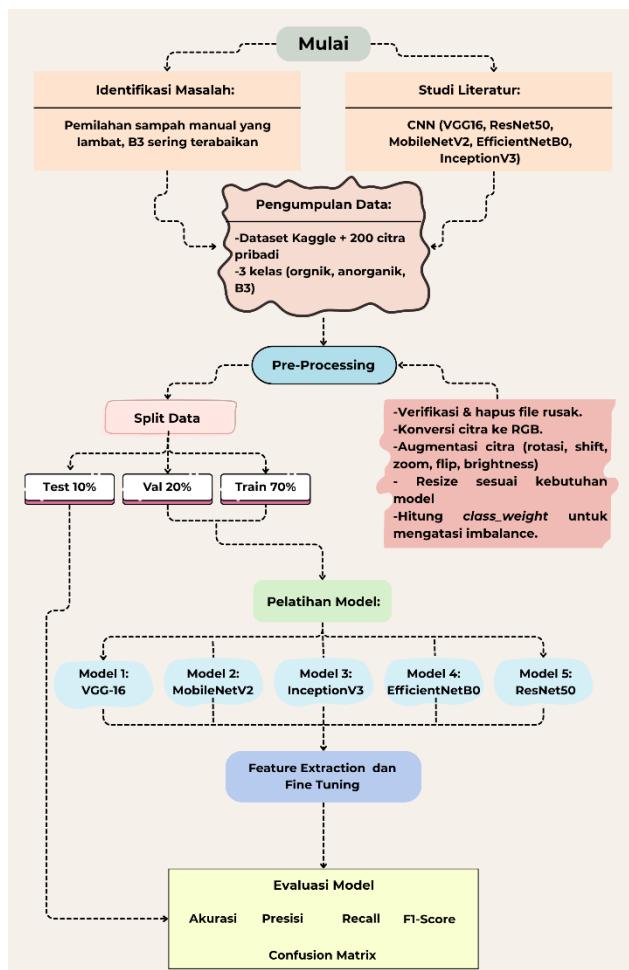
Tujuan utama penelitian ini adalah untuk mengimplementasikan arsitektur EfficientNetB0 dalam mengoptimalkan kinerja sistem klasifikasi sampah ke dalam tiga kategori, yaitu organik, anorganik, dan B3. Kinerja model tersebut dibandingkan dengan arsitektur *pre-trained* lainnya, yaitu VGG-16, InceptionV3, MobileNetV2, dan ResNet50 untuk mendapatkan hasil yang objektif. Kontribusi utama penelitian ini terletak pada penggunaan strategi untuk *class balancing* dan augmentasi data yang dikombinasikan dengan teknik *fine-tuning* untuk menghasilkan model yang akurat namun tetap efisien secara komputasi.

## 2. METODOLOGI PENELITIAN

Metode penelitian ini dirancang untuk menguji kinerja arsitektur EfficientNetB0 dengan membandingkannya terhadap empat model arsitektur CNN lainnya (VGG-16, InceptionV3, MobileNetV2, dan ResNet50) untuk menentukan model yang memiliki performa terbaik dalam klasifikasi sampah organik, anorganik, dan B3.

### 2.1 Alur Penelitian

Proses penelitian ini disusun secara sistematis untuk memastikan model yang dihasilkan memiliki akurasi dan generalisasi yang tinggi. Rangkaian prosedur penelitian, mulai dari identifikasi masalah hingga evaluasi performa model, dirangkum dalam diagram alir yang ditunjukkan pada Gambar 1.



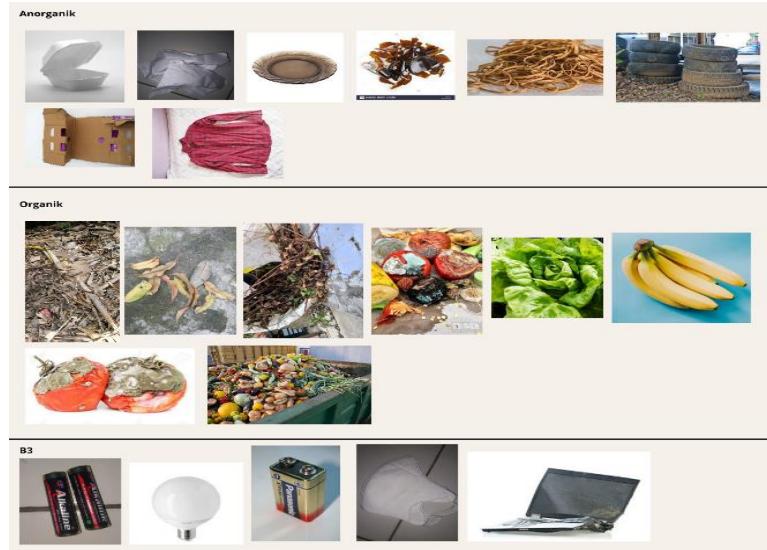
**Gambar 1.** Alur Penelitian

Berdasarkan Gambar 1, tahapan penelitian ini diawali dengan identifikasi masalah yang berfokus pada rendahnya efisiensi pemilihan sampah secara manual di Tempat Pembuangan Akhir (TPA) serta tingginya risiko kesalahan klasifikasi. Untuk menyelesaikan masalah tersebut, dilakukan studi literatur mendalam untuk mengkaji berbagai arsitektur CNN sebagai landasan pemilihan model. Proses dilanjutkan dengan pengumpulan data melalui integrasi dataset publik dan citra manual hingga mencapai total 7.018 citra. Sebelum tahap pemodelan, dilakukan *pre-processing* yang meliputi pembersihan data, konversi ke format RGB, *resizing*, serta dilakukan data *augmentation* dan *class balancing*. Selanjutnya, dilakukan pembagian data (*split data*) dengan rasio 70:20:10 untuk kebutuhan latih, validasi, dan uji. Pada tahap pelatihan model, metode *transfer learning* diimplementasikan melalui fase *feature extraction* dan *fine-tuning* secara bertahap. Rangkaian ini ditutup dengan evaluasi model secara komparatif menggunakan metrik akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix* untuk menentukan model yang paling optimal secara objektif.

## 2.2 Pengumpulan Data (*Data Collection*)

Data yang digunakan dalam penelitian ini berasal dari gabungan dua sumber untuk memastikan keragaman data. Sebagian besar dataset sekitar 6.800 citra diperoleh dari repositori dataset publik *Kaggle*. Selanjutnya, peneliti menambahkan lebih dari 200 gambar yang dikumpulkan secara manual.

Dataset awal terdiri dari 7.018 citra, namun setelah divalidasi, ditemukan 15 file citra yang rusak sehingga dihapus untuk menjaga kualitas data. Hasilnya, diperoleh 7.003 citra valid yang kemudian divalidasi dan diklasifikasikan ke dalam tiga kelas (anorganik, organik, dan B3). Gambar 2. menampilkan contoh citra dari masing-masing kelas untuk memberikan gambaran visual mengenai variasi data.



**Gambar 2.** Contoh Sampel Gambar dari Dataset

Berdasarkan Gambar 2, terlihat bahwa setiap kategori sampah memiliki karakteristik visual yang berbeda. Sampah organik direpresentasikan oleh sisa makanan dan bahan alam, sampah anorganik mencakup material plastik, kertas, baju, sterofoam, karet, dan kaca, sedangkan kategori B3 diwakili benda-benda yang memerlukan penanganan khusus seperti baterai, lampu, masker medis, dan kemasan bahan kimia. Keberagaman sampel pada Gambar 2 ini sangat krusial agar model dapat mempelajari fitur-fitur pembeda (tekstur, warna, dan bentuk) yang spesifik, sehingga dapat meminimalkan kesalahan klasifikasi antara sampah anorganik dan B3 yang sering kali memiliki kemiripan material dasar.

### 2.3 Persiapan Data (*Data Preparation*)

Untuk memastikan kualitas dan keseragaman data, tahap persiapan data terdiri dari beberapa tahapan yang berbeda:

#### a. Pembersihan dan Standarisasi Format

Seluruh dataset awal divalidasi untuk mengidentifikasi dan menghapus gambar yang rusak (*corrupted*). Sebanyak 14 file gambar yang tidak dapat dibaca berhasil dihapus, dan menyisakan 7.003 gambar valid. Semua gambar (termasuk format *grayscale*, *palette* (P), atau *transparansi* (RGBA)) diubah menjadi format standar 3-channel (RGB) dan disimpan sebagai file JPEG untuk menjaga konsistensi input bagi arsitektur CNN selama proses ekstraksi fitur.

#### b. *Dataset Splitting*

Kumpulan data yang sudah bersih dibagi secara acak (*random split*) menjadi tiga himpunan data terpisah dengan rasio 70:20:10, menggunakan *random\_state* untuk memastikan hasil pembagian data dapat direproduksi jika eksperimen diulang kembali. Rincian distribusi 7.003 gambar setelah pemisahan ditunjukkan pada Tabel 1.

**Tabel 1.** Distribusi Dataset Setelah Pemisahan

Kategori	Train	Val	Test	Total per Kelas
Anorganik	3.229	924	462	4.615
B3	1.281	366	184	1.831
Organik	389	112	56	557
Total	4.899	1.402	702	7.003

Berdasarkan Tabel 1, menunjukkan adanya ketidakseimbangan (*imbalance*) data yang cukup signifikan, dimana kelas anorganik mendominasi dataset sementara kelas organik memiliki jumlah sampel paling sedikit. Ketidakseimbangan ini menjadi landasan utama bagi peneliti untuk menerapkan strategi *class balancing* dan augmentasi data pada tahap selanjutnya. Tujuannya agar model tidak mengalami bias terhadap kelas mayoritas dan tetap memiliki sensitivitas yang tinggi dalam mengenali kategori sampah organik dan B3 meskipun dengan jumlah sampel yang lebih terbatas.

### 2.4 Augmentasi dan Penanganan Imbalance Data

Seperti yang ditunjukkan pada Tabel 1, dataset mengalami ketidakseimbangan (*imbalance*) yang signifikan pada kelas organik. Untuk mengatasi masalah ini, dua teknik utama diterapkan pada data pelatihan:

#### a. Augmentasi Data

Augmentasi data secara *real-time* diterapkan pada data latih menggunakan *ImageDataGenerator* Keras untuk variasi data dan mencegah *overfitting* [2], [20]. Teknik augmentasi yang diterapkan yaitu: rotasi acak (25°), pergeseran

horizontal/vertical (0.2), pembesaran acak (0.3), pembalikan horizontal, dan variasi kecerahan (0.8-1.2), teknik ini umum digunakan dalam penelitian klasifikasi citra [19].

#### b. Penanganan Imbalance

Metode *Class Balancing* digunakan selama pelatihan untuk mengatasi imbalance data [4], [5]. Untuk memastikan bahwa model memberikan perhatian proporsional pada setiap kelas, bobot kelas dihitung secara otomatis. Ini memberikan *loss* lebih tinggi pada kelas minoritas (organik: 4.19x, B3: 1.27x) dan lebih rendah pada kelas mayoritas (anorganik: 0.50x).

### 2.5 Arsitektur Model

Penelitian ini menerapkan metode *transfer learning*[12], [17] dengan membandingkan lima arsitektur CNN *pre-trained* dari *weights* ImageNet. *Transfer learning* telah terbukti efektif untuk tugas klasifikasi gambar [9], [11].

*Base model* (fitur ekstraktor) dan *custom head* (klasifikasi) yang seragam untuk setiap model terdiri dari *GlobalAveragePooling2D* untuk reduksi dimensi, *Dense* (256 atau 512 neuron) dengan aktivitas *ReLU*, *BatchNormalization* untuk stabilitas latihan, *Dropout* (0.5) untuk regulasi, dan lapisan *Dense* dengan 3 neuron dan aktivasi *softmax* sebagai output. Sesuai dengan standar arsitekturnya, ukuran input untuk VGG-16, ResNet50, MobileNetV2, dan EfficientNetB0 standarisasi ke (224, 224, 3) untuk InceptionV3 ukuran input standarisasinya (299, 299, 3).

### 2.6 Skenario Pelatihan

Seluruh model dilatih dengan parameter dan strategi yang konsisten untuk perbandingan objektif, dengan *batch\_size* 32 dan strategi dua tahap yaitu *Feature Extraction* (FE) dan *Fine-Tuning* (FT). Untuk mendapatkan adaptasi model yang optimal, strategi ini umum digunakan dalam *transfer learning* [13], [15].

#### a. Tahap 1: *Feature Extraction* (FE)

1. Seluruh lapisan di base model dibekukan *trainable=False*.
2. Hanya *custom head* yang dilatih oleh *optimizer Adam* (*learning rate*: 1e-4).
3. *EarlyStopping* (*patience*=12) dan *ReduceLROnPlateau* (*patience*=4) memantau pelatihan.

#### b. Tahap 2: *Fine-Tuning* (FT)

1. Sebagian lapisan atas base model mungkin antara 20-50 lapisan terakhir dibuka (*trainable* = *True*).
2. Model dilatih kembali dengan tingkat pembelajaran yang jauh lebih rendah (*LR*: 1e-5).
3. *EarlyStopping* (*patience*=10) dan *ReduceLROnPlateau* (*patience*=3) memantau pelatihan.

### 2.7 Metrik Evaluasi

Kinerja setiap model dievaluasi menggunakan test set dengan beberapa metrik evaluasi, yaitu *Accuracy*, *Precision*, *Recall*, *F1-Score* (dengan rata-rata *Macro* dan *Weighted*), dan *Confusion Matrix*. Dengan menggunakan metrik ini, kita dapat menilai seberapa jauh model mampu mengklasifikasikan data dengan benar untuk setiap kelasnya.

#### a. Akurasi (*Accuracy*)

Mengukur seberapa besar proporsi prediksi yang benar dibandingkan dengan total seluruh data uji. Semakin tinggi nilai akurasinya maka semakin baik juga performa modelnya secara umum.

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

Dimana *TP* adalah *True Positive*, *TN* adalah *True Negative*, *FP* adalah *False Positive*, dan *FN* adalah *False Negative*.

#### b. Presisi (*Precision*)

Mengevaluasi ketepatan prediksi positif yang benar dari seluruh data yang diprediksi. Nilai presisi yang tinggi menunjukkan bahwa model jarang memberikan prediksi positif yang salah (minim *False Positive*).

#### c. Recall

Mengukur kemampuan model untuk menemukan seluruh data positif yang sebenarnya. Nilai *recall* yang tinggi menunjukkan bahwa model berhasil mengidentifikasi sebagian besar data positif dengan benar (minim *False Negative*).

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

#### d. *F1-Score*

*F1-score* adalah rata-rata harmonik antara *precision* dan *recall*. Metrik ini digunakan saat diperlukan keseimbangan antara kedua metrik tersebut, terutama ketika distribusi data tidak seimbang. *F1-score* memberikan nilai tunggal yang representatif terhadap kemampuan model dalam menghasilkan klasifikasi yang stabil.

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

Kelima arsitektur dievaluasi menggunakan 702 gambar *test set* yang belum pernah dilihat sebelumnya.

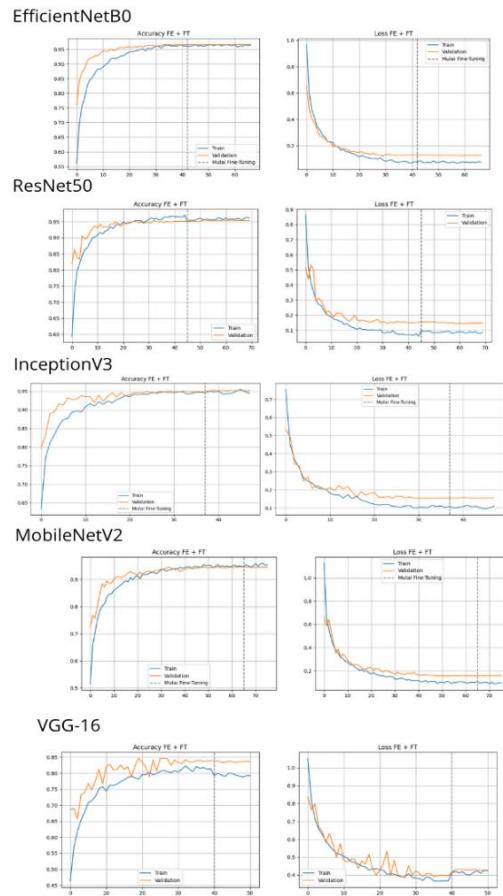
### 3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan analisis menyeluruh terhadap hasil eksperimen klasifikasi citra sampah menggunakan lima arsitektur *Convolutional Neural Network* (CNN). Tujuannya untuk memvalidasi kinerja dari arsitektur EfficientNetB0 dengan membandingkannya terhadap empat arsitektur *transfer learning* lainnya, yaitu VGG-16, InceptionV3, MobileNetV2, dan ResNet50 dalam membedakan tiga kategori sampah (organik, anorganik, dan B3). Analisis yang dilakukan tidak hanya berdasarkan metrik akurasi akhir, tetapi juga mencakup dinamika stabilitas selama pelatihan, evaluasi metrik performa, analisis kesalahan prediksi, dan implikasi hasil terhadap pengembangan sistem pengelolaan sampah cerdas yang dibahas dalam studi tinjauan oleh Ikhlas et al [7].

#### 3.1 Analisis Dinamika Pelatihan dan Stabilitas Model

Penerapan metode dalam penelitian ini dilakukan melalui dua tahapan utama. Pertama, fase *feature extraction* di mana lapisan base model dibekukan (*frozen*) untuk mempertahankan fitur umum ImageNet, sementara lapisan *custom head* dilatih untuk beradaptasi dengan kategori sampah. Mekanisme ini sangat efektif untuk menangani keterbatasan dataset melalui strategi *transfer learning*[10]. Kedua, fase *fine tuning* di mana sebagian lapisan atas dibuka (*unfrozen*) dan dilatih kembali dengan *learning rate* rendah ( $1e-5$ ) guna menyesuaikan model dengan karakteristik spesifik sampah lokal. Pendekatan dua tahap ini dilakukan untuk mengoptimalkan adaptasi fitur lokal, sesuai dengan teori Muslihati et.al [18] dan Risfendra et.al [16].

Evaluasi dinamika dilakukan untuk mengetahui seberapa cepat dan stabil setiap arsitektur dalam mempelajari fitur sampah dari data latih. Skenario pelatihan memiliki jangka waktu 70 *epoch*, tetapi juga memiliki mekanisme *EarlyStopping* dengan *patience* 10-12 *epoch*, untuk menghentikan proses secara otomatis jika tidak terjadi penurunan *validation loss*. Metode ini digunakan untuk mencegah terjadinya *overfitting* dan memastikan efisiensi sumber daya komputasi, penelitian yang dilakukan Chhabra et al [8] juga menyarankan metode ini.



**Gambar 3.** Perbandingan Kurva Akurasi dan Loss Validasi 5 Model Selama Pelatihan

Berdasarkan Gambar 3, model EfficientNetB0 dan InceptionV3 menunjukkan kemampuan belajar yang sangat efisien. Di awal fase pelatihan, kurva akurasi validasi menanjak tajam dan segera mencapai titik stabil (*plateau*). Mekanisme *EarlyStopping* berhasil menghentikan pelatihan sebelum mencapai batas maksimal ke-70 (EfficientNetB0 berhenti di *epoch* 67 dan InceptionV3 berhenti di *epoch* 48). Hal ini menunjukkan bahwa arsitektur modern ini memiliki kemampuan untuk menemukan pola fitur sampah yang optimal tanpa memerlukan waktu komputasi yang berlebihan.

Dalam penelitian yang dilakukan Risfendra et al [16], menemukan bahwa EfficientNetB0 sangat efektif dalam klasifikasi limbah dengan waktu komputasi yang cepat dan akurasi yang tinggi.

Di sisi lain, karakteristik stabilitas jangka panjang ditunjukkan oleh ResNet50 dan MobileNetV2. ResNet50 cenderung memanfaatkan waktu pelatihan yang lebih lama, sekitar 70 epoch. Grafik menunjukkan garis validasi yang sangat mulus dan menempel ketat dengan garis pelatihan, sedangkan MobileNetV2 menunjukkan performa stabil meskipun memiliki parameter yang jauh lebih sedikit. Kondisi ini menunjukkan bahwa penggunaan *Residual Connections* dan *Depthwise Separable Convolutions* sangat efektif untuk menjaga stabilitas gradien. Ini sesuai dengan temuan Firnando et al tentang arsitektur ringan [12].

Sedangkan VGG-16 menunjukkan grafik yang fluktuatif (*oscillating*) dengan celah (*gap*) yang lebar antara akurasi *training* dan *validation*. Sistem sering menghentikan pelatihan lebih awal bukan karena efisiensi, tetapi karena stagnasi *loss*, yang menunjukkan bahwa model mungkin terjebak dalam *local minima* atau mengalami *overfitting*. Instabilitas pada arsitektur *plain CNN* seperti VGG sesuai dengan masalah yang juga ditemukan dalam studi awal klasifikasi sampah yang dilakukan oleh Haqqi et al [2].

Keberhasilan model-model modern seperti EfficientNetB0 dan MobileNetV2 dalam mencapai konvergensi yang stabil tidak terlepas dari strategi *Hyperparameter Tuning* dan penerapan data *Augmentation* pada *pre-processing*. Dalam eksperimen ini, augmentasi berupa rotasi (*rotation range* 25 derajat), pergeseran (*shift*), dan zoom terbukti sangat penting. Sampah adalah objek *non-rigid* yang sering kali ditemukan dalam kondisi penyok, terlipat, atau tertumpuk dengan orientasi acak. Tanpa adanya augmentasi, model cenderung menghafal posisi objek (*overfitting spasial*). Namun, dengan variasi sintetis yang dihasilkan oleh *ImageDataGenerator*, model dipaksa untuk mempelajari fitur invarian (tekstur dan pola permukaan) daripada bentuk geometris yang kaku. Ini dapat dilihat dengan jelas dalam peningkatan akurasi fase *fine-tuning* di model InceptionV3 dan MobileNetV2, dimana pembukaan layer konvolusi terakhir (*unfreezing*) memungkinkan bobot model beradaptasi dengan fitur spesifik sampah lokal yang tidak ada pada dataset asli *ImageNet*, seperti tekstur label kemasan produk atau karakteristik plastik kresek yang spesifik. Metode ini memvalidasi teori yang ditemukan oleh Muslihati et al mengenai pentingnya adaptasi fitur lokal dalam *transfer learning* [18].

### 3.2 Evaluasi Mendalam Kinerja Arsitektur

Untuk mengevaluasi kelima arsitektur, 702 gambar set tes yang belum pernah dilihat sebelumnya. Analisis pada bagian ini secara khusus menyoroti EfficientNetB0 sebagai model dengan kinerja terbaik, yang menjadi dasar utama dalam mendukung klaim peningkatan performa pada penelitian ini. Berikut analisis rinci terhadap performa masing-masing arsitektur berdasarkan *Classification Report*.

#### a. Analisis Kinerja EfficientNetB0

Model EfficientNetB0 menunjukkan kinerja terbaik di antara kelima model, dengan akurasi pengujian 96.87%. Detail performa per kelas dari model ini disajikan pada Tabel 2.

**Tabel 2.** Clasification Report Model EfficientNetB0

	precision	recall	f1-score	support
anorganik	0.98	0.98	0.98	462
b3	0.95	0.94	0.94	184
organik	0.98	0.96	0.97	56
accuracy			0.97	702
macro avg	0.97	0.96	0.96	702
weighted avg	0.97	0.97	0.97	702

Pada Tabel 2 menunjukkan dominasi model ini dengan nilai *precision* dan *recall* yang sangat merata di angka 0.97-0.98 untuk semua kelas. Keunggulan ini didorong oleh metode *Compound Scaling* dan blok *Squeeze-and-Excitation* (SE), yang memungkinkan jaringan untuk memfokuskan perhatian pada fitur relevan sampah. Hasil ini sejalan dengan penelitian oleh Kurniawan et al dan Risfendra et al yang menyimpulkan bahwa EfficientNetB0 menawarkan kombinasi terbaik antara akurasi dan efisiensi untuk klasifikasi sampah [13], [16].

#### b. Analisis Kinerja ResNet50

Hasil pengujian model ResNet50 menempati posisi kedua terbaik dengan akurasi pengujian sebesar 96.72%.

**Tabel 3.** Clasification Report Model ResNet50

	precision	recall	f1-score	support
anorganik	0.98	0.97	0.98	462
b3	0.94	0.95	0.95	184
organik	0.98	0.96	0.97	56
accuracy			0.97	702
macro avg	0.97	0.96	0.96	702
weighted avg	0.97	0.97	0.97	702

Berdasarkan pada Tabel 3, menunjukkan bahwa kinerja model ini yang sangat seimbang dengan *F1-Score* 0.98 (Anorganik), 0.95 (B3), dan 0.97 (Organik). Salah satu tantangan terbesar dalam klasifikasi sampah membedakan kategori B3, seperti botol pembersih atau kaleng aerosol yang sering memiliki bentuk yang mirip dengan sampah anorganik. Arsitektur *Residual Blocks* memungkinkan aliran informasi gradien melewati beberapa layer tanpa hambatan, sehingga fitur-fitur semantik halus tetap terjaga selama proses konvolusi. Temuan ini memperkuat hasil dari penelitian Grace et al [19] yang juga mencatat stabilitas tinggi ResNet50 dalam menangani fitur citra kompleks.

#### c. Analisis Kinerja MobileNetV2

Model MobileNetV2 menunjukkan kemampuannya sebagai arsitektur yang ringan dengan akurasi pengujian 95.16%.

**Tabel 4.** Clasification Report Model MobileNetV2

	precision	recall	f1-score	support
anorganik	0.97	0.96	0.97	462
b3	0.91	0.93	0.92	184
organik	0.96	0.93	0.95	56
accuracy			0.95	702
macro avg	0.95	0.94	0.94	702
weighted avg	0.95	0.95	0.95	702

Tabel 4 menunjukkan bahwa model ini mampu bersaing dengan model besar, meskipun terdapat sedikit penurunan performa pada kelas B3 dengan *F1-Score* 0.92 akibat penggunaan *Depthwise Separable Convolutions*. Meskipun ada *trade-off* kecil pada akurasi kelas sulit, efisiensi model ini sangat krusial untuk implementasi pada perangkat terbatas, seperti yang disimpulkan dalam studi Qurrota A'yun et al [21].

#### d. Analisis Kinerja InceptionV3

Model InceptionV3 menempati posisi tengah yang solid dengan akurasi pengujian 95.73%.

**Tabel 5.** Clasification Report Model InceptionV3

	precision	recall	f1-score	support
anorganik	0.97	0.96	0.97	462
b3	0.93	0.93	0.93	184
organik	0.92	0.98	0.95	56
accuracy			0.96	702
macro avg	0.94	0.96	0.95	702
weighted avg	0.96	0.96	0.96	702

Menurut Tabel 5, model ini memiliki nilai *recall* yang tertinggi untuk kelas organik (0.98) dibandingkan dengan model lain. Kemampuan ini berasal dari desain *Inception Module* yang memanfaatkan filter multi-skala yang dapat menangkap variasi ukuran ekstrem pada sampah organik. Keunggulan arsitektur ini dalam menangani berbagai fitur natural juga ditemukan dalam penelitian yang dilakukan Nur et al untuk mendeteksi penyakit pada tanaman [17].

#### e. Analisis Kinerja VGG-16

Model VGG-16 menunjukkan performa terendah secara signifikan dengan akurasi 86.61%.

**Tabel 6.** Clasification Report Model VGG-16

	precision	recall	f1-score	support
anorganik	0.93	0.88	0.90	462
b3	0.76	0.81	0.78	184
organik	0.77	0.95	0.85	56
accuracy			0.87	702
macro avg	0.82	0.88	0.85	702
weighted avg	0.87	0.87	0.87	702

Pada Tabel 6 mengungkapkan kelemahan fatal pada *F1-Score* kelas B3 yang hanya mencapai 0.78. Untuk dataset yang heterogen ini, arsitektur VGG yang mengandalkan tumpukan layer convolusi linier tanpa *skip connection* terbukti kurang efisien. Hasil ini kontras dengan penelitian terdahulu, namun konsisten dengan penelitian dari Shafeek et al [9] yang menyarankan perlunya modifikasi pada arsitektur konvensional untuk meningkatkan akurasi.

### 3.3 Perbandingan Kinerja Kelima Model

Menyajikan perbandingan kinerja dari kelima arsitektur dirangkum pada Tabel 7, diurutkan dari akurasi tertinggi ke terendah.

**Tabel 7.** Perbandingan Metrik Evaluasi Akhir 5 Arsitektur CNN

Arsitektur	Akurasi	Precision	Recall	F1-Score
EfficientNetB0	96.87%	0.97	0.96	0.96
ResNet50	96.72%	0.97	0.96	0.96
InceptionV3	95.73%	0.94	0.96	0.95
MobileNetV2	95.16%	0.95	0.94	0.94
VGG-16	86.61%	0.82	0.88	0.85

Secara keseluruhan, model EfficientNetB0 mendapat akurasi tertinggi 96.87%, dan ikuti ketat oleh ResNet50. Empat dari lima arsitektur (EfficientNetB0, ResNet50, InceptionV3, dan MobileNetV2) dapat mencapai tingkat akurasi di atas 95%. Ini membuktikan efektivitas *transfer learning* dalam menangani keterbatasan dataset, sejalan dengan penelitian yang dilakukan Dolly et al [10]. Selain itu, hasil ini menegaskan bahwa kedalaman jaringan semata tidak cukup tanpa dukungan dari arsitektur yang cerdas untuk mengatasi *Vanishing Gradient*. Pergeseran tren dari model berat menuju model yang efisien dan akurat ini selaras dengan penelitian yang dilakukan oleh Ikhlas et al [7].

Selain itu, tingginya nilai *recall* pada kelas minoritas (organik) dihampir semua model modern rata-rata ( $>0.94$ ) membuktikan bahwa strategi penanganan data berhasil. Penerapan *Class Balancing* terbukti efektif untuk mencegah bias model terhadap kelas mayoritas. Keberhasilan metode ini sejalan dengan rekomendasi studi Listyalina et al yang menekankan pertingginya *pre-processing* data yang tepat untuk meningkatkan sensitivitas model terhadap kategori sampah organik [1].

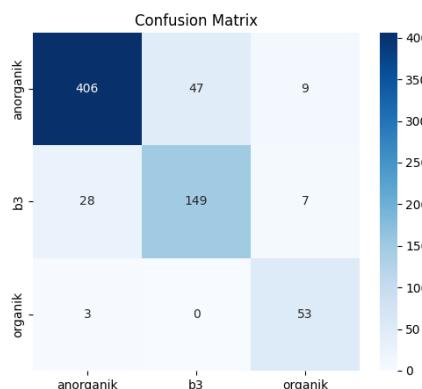
### 3.3.1 Analisis Efisiensi Komputasi dan Waktu Pelatihan

Efisiensi komputasi adalah komponen penting dalam pengoperasian sistem cerdas selain akurasi. Berdasarkan log pelatihan yang direkam menggunakan Google Colab (T4 GPU) menunjukkan perbedaan yang signifikan dalam durasi pelatihan per *epoch* antar arsitektur. Model VGG-16 tercatat sebagai model yang paling boros sumber daya, dengan rata-rata waktu pelatihan mencapai 118-120 detik per *epoch* dan ukuran model yang sangat besar akibat penggunaan *fully connected layers* yang masif mencapai 138 juta parameter. Sebaliknya, MobileNetV2 dan EfficientNetB0 memiliki efisiensi waktu yang superior dengan rata-rata 106-109 detik per *epoch* tetapi mereka juga dapat mencapai konvergensi lebih cepat.

Secara spesifik, InceptionV3 mencatatkan konvergensi tercepat secara jumlah iterasi, dimana model ini hanya memerlukan total 48 *epoch* gabungan antara *feature extraction* dan *fine tuning* sebelum mekanisme *Early Stopping* menghentikan pelatihan. Hal ini berbeda dengan EfficientNetB0 yang memerlukan 67 *epoch*, serta MobileNetV2 dan ResNet50 yang membutuhkan proses pelatihan lebih panjang mencapai 76 dan 70 *epoch* untuk menstabilkan bobot. Efisiensi konvergensi pada InceptionV3 ini menunjukkan bahwa fitur-fitur yang diekstraksi oleh modul *Inception* sudah sangat representatif terhadap dataset sampah bahkan sejak awal pelatihan. Fakta ini, digabungkan dengan efisiensi inferensi MobileNetV2, memberikan opsi fleksibel bagi pengembang sistem: menggunakan InceptionV3 untuk pelatihan cepat, atau MobileNetV2 untuk *deployment* pada perangkat *low-power* seperti Raspberry Pi, sebagaimana didukung oleh Pieters [20].

### 3.4 Analisis Kesalahan (Failure Analysis)

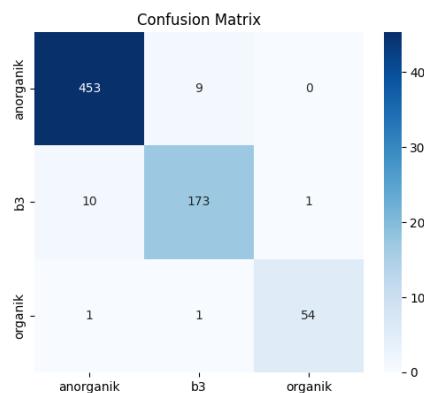
Analisis visual menggunakan *Confusion Matrix* dilakukan untuk membedah distribusi kesalahan prediksi pada model terbaik dan terburuk.



**Gambar 4.** Confusion Matrix VGG-16

Berdasarkan *confusion matrix* yang ditunjukkan pada Gambar 4, model VGG-16 kelas B3 memiliki tingkat kesalahan prediksi tertinggi. Ada 28 sampel B3 dianggap anorganik, dan 7 sampel dianggap organik. Angka kesalahan yang tinggi ini menunjukkan bahwa model VGG-16 masih mengalami kesulitan untuk mengidentifikasi ciri-ciri kelas B3

dibandingkan dengan kelas lainnya. Analisis lebih lanjut menunjukkan bahwa ambiguitas visual antara kelas anorganik dan B3 menjadi penyebab utamanya. Banyak sampah B3 seperti kaleng aerosol atau botol pembersih lantai, terbuat dari logam yang memiliki tekstur dan refleksi cahaya yang mirip dengan botol minuman (anorganik). Model VGG-16 yang kurang kuat dalam ekstrasi fitur halus cenderung hanya berfokus pada bentuk silinder dasar, sehingga gagal menangkap fitur kontekstual seperti bentuk *nozzle* atau logo peringatan bahaya.



**Gambar 5.** Confusion Matrix EfficientNetB0

Sementara itu, berdasarkan *confusion matrix* pada Gambar 5, model EfficientNetB0 menunjukkan peningkatan akurasi yang konsisten pada semua kelas, menjadikannya jauh lebih stabil dibandingkan model VGG-16. Kemampuan model untuk mengurangi angka kesalahan pada kelas B3 ke kelas anorganik adalah peningkatan terbesar. Mekanisme *Squeeze-and-Excitation* (SE), yang secara adaptif mengkalibrasi ulang respon fitur, dapat berkontribusi pada keberhasilan ini. Mekanisme ini memungkinkan model untuk memprioritaskan fitur distingatif, seperti label khusus pada kemasan B3, sambil mengabaikan kemiripan bentuk fisik botol yang sering menipu model lain. Namun, beberapa sampel sampah organik yang telah terdegradasi parah (hancur), dengan tekstur yang tidak jelas dan mirip dengan kotoran atau kertas basah (anorganik), masih menghadapi masalah kecil (dianggap ketras basah/anorganik). Hasil ini menunjukkan bahwa seperti yang disarankan oleh Malik et al, variasi dataset dengan kondisi fisik ekstrim harus diperluas untuk penelitian lanjutan [4].

Analisis visual lebih mendalam dilakukan dengan mengekstraksi sampel citra hasil prediksi untuk mengkonfirmasi ketepatan fitur yang dipelajari model, yang telah ditunjukkan pada Gambar 6.



**Gambar 6.** Sampel Prediksi Benar dan Salah Model EfficientNetB0 pada Data Uji

Melalui visualisasi pada Gambar 6, dapat dilihat bahwa model menangkap pola tekstur permukaan yang konsisten, seperti serat pada sampah organik dan refleksi material pada botol anorganik, jika prekdiksinya benar. Namun ketika prediksi salah, ditemukan bahwa model cenderung mengalami ambiguitas ketika objek sampah mengalami kerusakan fisik atau deformasi yang signifikan. Sebagai contoh, sampah anorganik yang remuk dan kotor dapat memiliki fitur visual yang menyerupai limbah organik (tekstur tidak beraturan). Fenomena ini menunjukkan bahwa, meskipun *compound scaling* pada EfficientNetB0 sangat kuat, kemiripan fitur antar kelas (*inter-class similarity*) akibat kondisi sampah yang ekstrem tetap menjadi tantangan dalam proses klasifikasi citra di lapangan.

## 4. KESIMPULAN

Penelitian ini menunjukkan bahwa arsitektur *deep learning* EfficientNetB0, yang menggunakan pendekatan *transfer learning* berhasil diterapkan untuk meningkatkan kinerja sistem klasifikasi sampah organik, anorganik, dan B3. Berdasarkan hasil eksperimen yang dilakukan, model EfficientNetB0 menunjukkan performa yang paling unggul dibandingkan dengan empat arsitektur *pre-trained* lainnya, yaitu VGG-16, InceptionV3, MobileNetV2, dan ResNet50, dengan akurasi akhir sebesar 96,87%. Penggunaan strategi penyeimbangan kelas (*class balancing*) dan teknik augmentasi data menjadi faktor kunci dalam mengatasi ketidakseimbangan dataset dan meningkatkan generalisasi model visi komputer secara signifikan. Keberhasilan model dalam mencapai metrik evaluasi yang stabil menunjukkan bahwa metode yang diusulkan memiliki reliabilitas yang baik dalam mengenali karakteristik citra sampah dalam berbagai kondisi latar belakang. Temuan ini menegaskan bahwa model yang efisien secara komputasi tetapi memiliki kapasitas fitur yang dapat diintegrasikan ke dalam sistem pemilahan sampah di Tempat Pembuangan Akhir (TPA) untuk mendukung efisiensi pengelolaan limbah yang berkelanjutan. Penelitian selanjutnya dapat difokuskan pada pengujian model menggunakan perangkat keras secara *real-time* dan penambahan variasi jenis sampah yang lebih spesifik untuk menguji ketangguhan model di lingkungan nyata yang lebih kompleks. Oleh karena itu, solusi berbasis kecerdasan buatan ini diharapkan dapat menjadi rujukan penting dalam upaya otomatisasi pengelolaan sampah digital di masa depan.

## REFERENCES

- [1] L. Listyalina, R. Retno Utami, U. Fadzilia Arifin, and N. Putri, "The Application of Artificial Intelligence in Waste Classification as an Effort In Plastic Waste Management," *Jurnal Informatika dan Teknologi Informasi*, vol. 21, no. 1, pp. 1–13, Jun. 2024, doi: 10.31515/telematika.v21i1.11977.
- [2] M. Haqqi, L. Rochmah, A. Dwi Safitri, and R. Adhi Pratama, "Implementation of Machine Learning to Identify Types of Waste Using CNN Algorithm," *Jurnal Fasilkom - teknologi Informasi dan Ilmu Komputer Universitas Muhammadiyah Riau*, vol. 14, no. 3, pp. 761–765, Dec. 2024, doi: 10.37859/jf.v14i3.8116.
- [3] T. H. Yan, S. N. M. Azam, Z. M. Sani, and A. Azizan, "Accuracy study of image classification for reverse vending machine waste segregation using convolutional neural network," *International Journal of Electrical and Computer Engineering*, vol. 14, no. 1, pp. 366–374, Feb. 2024, doi: 10.11591/ijece.v14i1.pp366-374.
- [4] M. Malik et al., "Waste Classification for Sustainable Development Using Image Recognition with Deep Learning Neural Network Models," *Sustainability (Switzerland)*, vol. 14, no. 12, Jun. 2022, doi: 10.3390/su14127222.
- [5] D. F. Kuncoro, A. Wirasto, and D. N. Triwibowo, "Klasifikasi Jenis Sampah Berbasis Convolutional Neural Network dengan Optimasi Hyperparameter Tuning Arsitektur MobileNet," *Methomika: Jurnal Manajemen Informatika & Komputerisasi Akuntansi*, vol. 9, no. 1, pp. 130–144, Apr. 2025, doi: 10.46880/jmika.Vol9No1.pp130-144.
- [6] D. Sadida Aulia, H. Arwoko, and E. Asmawati, "Klasifikasi Sampah Rumah Tangga Menggunakan Metode Convolutional Neural Network," *METIK JURNAL*, vol. 8, no. 2, pp. 114–120, Dec. 2024, doi: 10.47002/metik.v8i2.956.
- [7] A. Ikhlas and B. Hendrik, "Literature Review: Studi Komparasi Klasifikasi Sampah menggunakan Algoritma Deep Learning," *Sistemasi: Jurnal Sistem Informasi*, vol. 14, no. 3, pp. 2540–9719, Apr. 2025, doi: 10.32520/stmsi.v14i3.5163.
- [8] M. Chhabra, B. Sharai, 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.
- [9] D. Shafeek, H. W. Hilou, and M. Ahmed, "Classification of waste images using deep learning technique," *Journal of Applied Research and Technology*, vol. 23, pp. 381–391, Aug. 2025, doi: 10.22201/icat.24486736.e.2025.23.4.2578.
- [10] D. I. S. Huta Julu and D. Nurdyiah, "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.
- [11] W. Vidiadivani and G. K. I. Suhartana, "Klasifikasi Jenis Sampah Menggunakan Metode Transfer Learning pada Convolutional Neural Network (CNN)," *JELIKU: Jurnal Elektronik Ilmu Komputer Udayana*, vol. 12, no. 3, pp. 589–596, Feb. 2024, Accessed: Dec. 18, 2025. [Online]. Available: <https://ojs.unud.ac.id/index.php/JLK>
- [12] R. Firnando, M. Ali Buchari, A. Dwi Marjusalinah, and R. Fadli Isnanto, "Performance analysis of MobileNetV2 based automatic waste classification using transfer learning," *Jurnal Mandiri IT*, vol. 14, no. 1, pp. 257–268, Jul. 2025, doi: 10.35335/mandiri.v14i1.451.
- [13] T. Kurniawan, K. Khadijah, and R. Kusumaningrum, "An Efficient Model for Waste Image Classification Using EfficientNet-B0," *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 3, pp. 1147–1158, Jun. 2025, doi: 10.52436/1.jutif.2025.6.3.4417.
- [14] I. S. Lestari, J. Jumadi, and N. Lukman, "Implementasi Convolutional Neural Network dengan Pre-Trained Model MobileNetV2 untuk Deteksi Kolestrol," *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 9, no. 2, pp. 173–183, Jul. 2024, doi: 10.36341/rabit.v9i2.4732.
- [15] L. E. Elvitaria, I. P. Sari, and T. I. Buchari, "Klasifikasi Telur Cacing Berbasis Gambar Menggunakan Jaringan Saraf Konvolusional," *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 10, no. 2, pp. 518–526, Jul. 2025, doi: 10.36341/rabit.v10i2.6207.
- [16] Risfendra, G. F. Ananda, and H. Setyawan, "Deep Learning-Based Waste Classification with Transfer Learning Using EfficientNet-B0 Model," *Jurnal RESTI : Rekayasa Sistem dan Teknologi Informasi*, vol. 8, no. 4, pp. 535–541, Aug. 2024, doi: 10.29207/resti.v8i4.5875.
- [17] K. N. A. Nur, N. I. Addyna, A. P. Windarto, A. Wanto, and P. Poningsih, "Optimization of the InceptionV3 Architecture for Potato Leaf Disease Classification," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 10, no. 4, pp. 849–858, May 2025, doi: 10.33480/jitk.v10i4.6554.
- [18] Muslihati, S. Sahibu, I. Taufik, and P. Studi Sistem Komputer, "Implementation of the Convolutional Neural Network Algorithm for Classifying Types of Organic and Non-Organic Waste," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 3, pp. 840–852, 2024, doi: 10.57152/malcom.v7i2.1346.

- [19] S. J. Grace and D. Gunawan, "Perbandingan CNN, RESNET50, dan Vision Transformer untuk Klasifikasi Kanker Payudara Berbasis Web," *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 10, no. 2, pp. 945–956, Jul. 2025, doi: 10.36341/rabit.v10i2.6420.
- [20] L. Stephen Pieters, "Development of Automatic Waste Classification System using CNN Based Deep Learning to Support Smart Waste Management," *Jurnal Inovtek Polbeng - Seri Informatika*, vol. 10, no. 1, pp. 214–224, Mar. 2025, doi: 10.35314/wst8mh87.
- [21] A. A. Qurrota, Suhartono, and T. Mukti Lestari, "Implementation of Convolutional Neural Network in Image-Based Waste Classification," *Journal of Applied Informatics and Computing (JAIC)*, vol. 9, no. 4, pp. 1778–1784, Aug. 2025, doi: 10.30871/jaic.v9i4.9829.