



## *Optimization of Convolutional Neural Network Algorithm with Efficientnet-B0 and Resnet-50 Architecture for Waste Type Classification*

### **Optimasi Algoritma Convolutional Neural Network dengan Arsitektur Efficientnet-B0 dan Resnet-50 untuk Klasifikasi Jenis Sampah**

Wildan Muhammad Ardana<sup>1\*</sup>, Kusri<sup>2</sup>

<sup>1,2</sup>Program Studi Magister Informatika, Universitas Amikom Yogyakarta, Yogyakarta

E-Mail: <sup>1</sup>wildan1999muhammad@students.amikom.ac.id, <sup>2</sup>kusri@amikom.ac.id

Received Apr 24th 2025; Revised Sep 06th 2025; Accepted Sep 06th 2025; Available Online Oct 30th 2025

Corresponding Author: Wildan Muhammad Ardana

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

#### **Abstract**

*This research develops an automatic waste classification system using deep learning to distinguish between organic and recyclable waste. The study was conducted using a dataset from Kaggle consisting of 25,077 images of waste with two main categories: organic (O) and recyclable (R). The research methodology focuses on a comparison of transfer learning using the EfficientNet-B0 and ResNet-50 architectures. Modern data augmentation techniques (rotation, zoom, flip) were applied to improve model generalization, and Keras Tuner was used for systematic hyperparameter optimization. The results show that the EfficientNet-B0 model, after hyperparameter optimization, achieved the best performance with a testing accuracy of 97.25%. This architecture significantly outperformed ResNet-50 (93.39% accuracy) in the comparison scenario. The detailed classification report for the best model shows excellent and balanced performance in classifying organic waste (precision: 0.93, recall: 0.98) and recyclable waste (precision: 0.97, recall: 0.91). The fast evaluation time indicates the potential for real-time system implementation. This research demonstrates the effectiveness of transfer learning with modern architectures combined with hyperparameter optimization to create a highly accurate and efficient automated waste classification solution.*

*Keyword: Convolutional Neural Network, Data Augmentation, EfficientNet-B0, Garbage Classification, ResNet-50*

#### **Abstrak**

Penelitian ini mengembangkan sistem klasifikasi sampah otomatis menggunakan *deep learning* untuk membedakan sampah organik dan dapat didaur ulang. Penelitian dilakukan menggunakan *dataset* dari Kaggle yang terdiri dari 25.077 gambar sampah dengan dua kategori utama: organik (O) dan dapat didaur ulang (R). Metodologi penelitian berfokus pada perbandingan *transfer learning* menggunakan arsitektur EfficientNet-B0 dan ResNet-50. Teknik data *augmentation* modern (rotasi, zoom, flip) diterapkan untuk meningkatkan generalisasi model, dan *Keras Tuner* digunakan untuk optimasi *hyperparameter* secara sistematis. Hasil penelitian menunjukkan bahwa model EfficientNet-B0, setelah optimasi *hyperparameter*, mencapai performa terbaik dengan akurasi pengujian 97.25%. Arsitektur ini secara signifikan mengungguli ResNet-50 (akurasi 93.39%) dalam skenario perbandingan. Laporan klasifikasi detail untuk model terbaik menunjukkan kinerja yang sangat baik dan seimbang dalam mengklasifikasi sampah organik (presisi: 0.93, *recall*: 0.98) dan sampah dapat didaur ulang (presisi: 0.97, *recall*: 0.91). Waktu evaluasi yang cepat mengindikasikan potensi implementasi sistem secara *real-time*. Penelitian ini membuktikan efektivitas *transfer learning* dengan arsitektur modern yang dikombinasikan dengan optimasi *hyperparameter* untuk menciptakan solusi klasifikasi sampah otomatis yang sangat akurat dan efisien.

Kata Kunci: Augmentasi Data, Convolutional Neural Network, EfficientNet-B0, Klasifikasi Sampah, ResNet-50

## **1. PENDAHULUAN**

Masalah lingkungan utama yang menjadi tantangan kritis di hampir semua negara maju dan berkembang adalah pembuangan limbah sampah [1]. Daur ulang menjadi semakin penting, karena merupakan satu-satunya cara agar kita dapat memiliki lingkungan yang bersih dan berkelanjutan. Salah satu permasalahan serius yang dihadapi oleh masyarakat Indonesia adalah masalah sampah yang jumlahnya terus



bertambah setiap tahunnya. Dengan bertambahnya jumlah penduduk setiap tahunnya, maka jumlah dan jenis sampah juga semakin bertambah [2].

Menurut catatan *World Population Review* [3] Indonesia berada di peringkat kelima sebagai negara penyumbang sampah plastik ke laut, sampah plastik di laut Indonesia mencapai 56 ribu ton pada 2021. Di atas Indonesia ada China dengan kontribusi terhadap sampah plastik mencapai 70 ribu ton. Sementara, Filipina merupakan negara penyumbang sampah plastik terbesar di lautan, yaitu mencapai 350 ribu ton pada 2021. India dan Malaysia berada di posisi selanjutnya dengan sampah plastik di laut masing-masing 126 ribu ton dan 73 ribu ton. Berdasarkan data (Kementerian Lingkungan Hidup dan Kehutanan Republik Indonesia Indonesia, 2024) pada Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) 2023, Timbulan Sampah di Indonesia sebesar 38,315,969.64 ton/tahun, Penanganan Sampah baru 48.03% yaitu 18,401,524.14 (ton/tahun), Sampah yang Tidak Terkelola sebesar 38.33% yaitu 14,687,895.25 (ton/tahun), Sampah terkelola sebesar 61.67% yaitu 23,628,074.39 (ton/tahun).

Convolutional Neural Network (CNN) [4] merupakan model klasik dalam tugas pengenalan dan klasifikasi citra. Dalam pengenalan citra sampah, mengeksplorasi berbagai arsitektur CNN atau varian yang ditingkatkan dapat meningkatkan kinerja klasifikasi. Misalnya, struktur jaringan yang lebih dalam seperti ResNet, Inception, dan EfficientNet dapat dicoba untuk meningkatkan kemampuan representasi dan generalisasi model. CNN telah banyak digunakan dalam bidang pengenalan dan klasifikasi citra sampah. CNN merupakan model pembelajaran mendalam yang dirancang khusus untuk pemrosesan citra, dan memiliki keunggulan dalam ekstraksi fitur hierarkis dan pemodelan lokalitas spasial.

Pada penelitian yang dilakukan [5] Model CNN, seperti DenseNet121, meningkatkan teknologi pengenalan gambar tradisional dan merupakan pendekatan dominan saat ini untuk pengenalan gambar. Kumpulan data tolok ukur yang terkenal, yaitu TrashNet, yang terdiri dari total 2527 gambar dengan enam kategori limbah yang berbeda digunakan untuk mengevaluasi kinerja CNN. Untuk meningkatkan akurasi klasifikasi limbah yang didorong oleh CNN, metode penambahan data dapat diadopsi untuk melakukannya, tetapi penyempurnaan hiperparameter optimal dari lapisan yang terhubung penuh CNN tidak pernah digunakan.

Dalam penelitian lainnya yang dilakukan oleh [6] Proses daur ulang sampah bergantung pada kemampuan untuk mengambil kembali karakteristik sebagaimana adanya di posisi alaminya, dan mengurangi polusi serta membantu lingkungan yang berkelanjutan. Baru-baru ini, metode *Deep Learning* (DL) telah digunakan secara cerdas untuk mendukung pengelolaan sampah yang strategis dan prosedur terkait, termasuk penangkapan, klasifikasi, pengomposan, dan pembuangan. Pemilihan teknik DL yang optimal untuk mengkategorikan dan memperkirakan sampah merupakan proses yang panjang dan sulit. Penelitian ini menyajikan klasifikasi sampah cerdas menggunakan Hybrid CNN - Long Short-Term Memory (LSTM) dengan pembelajaran transfer untuk pembangunan berkelanjutan, Analisis eksperimental dilakukan pada sampel *dataset* TrashNet, dengan 27027 gambar dipisahkan menjadi dua kelas limbah organik 17005 dan limbah daur ulang 10 025 digunakan untuk mengevaluasi kinerja model yang diusulkan.

Penelitian yang dilakukan [7] melakukan penelitian untuk mengembangkan metode untuk mengidentifikasi sampah *organic* dan non-organik menggunakan teknik pengenalan citra komputer berbasis CNN dengan arsitektur EfficientNet-B0. Tujuan utama penelitian ini adalah untuk membedakan antara sampah organik dan non-organik dalam citra. Pilihan menggunakan CNN dengan arsitektur EfficientNet-B0 merupakan bagian penting dari solusinya. EfficientNet-B0 dikenal karena keseimbangannya antara akurasi dan efisiensi komputasi.

Penelitian [8] ini memberikan pendekatan tradisional untuk pemilahan limbah bergantung pada tenaga kerja manual, yang memakan waktu, tidak efisien, dan rentan terhadap kesalahan. Meskipun demikian, kemajuan pesat teknik *computer vision* telah membuka jalan untuk mengotomatiskan klasifikasi sampah, yang menghasilkan peningkatan efisiensi, kelayakan, dan manajemen. Dalam hal ini, dalam studi ini, penyelidikan komprehensif tentang klasifikasi sampah menggunakan algoritma terkini, seperti CNN, serta model pra-terlatih seperti DenseNet169, MobileNetV2, dan ResNet50V2 telah disajikan. Percobaan menunjukkan bahwa algoritma ResNet50V2 mencapai hasil tertinggi dalam hal Akurasi, Presisi, *Recall*, dan skor F1 masing-masing sebesar 98,95%, 98,35%, 98,38, dan 98,38%.

Untuk itu pada penelitian ini akan dilakukan klasifikasi jenis sampah menggunakan CNN dengan membandingkan model EfficientNet dan Resnet dengan melakukan klasifikasi jenis sampah. Perbandingan ini tidak hanya menempatkan hasil penelitian dalam konteks yang lebih luas, tetapi juga menyoroti keunikan dan kontribusi dari pendekatan yang diambil. menerapkan konversi *grayscale* dan *resize* gambar ke ukuran yang jauh lebih kecil (50x50 piksel) dengan argumen bahwa model yang lebih sederhana dan *preprocessing* yang tepat lebih efektif untuk *dataset* ini dan dapat menghindari *overfitting*. Sebaliknya, penelitian ini menggunakan gambar berwarna dengan resolusi lebih tinggi (224x224 piksel) dan arsitektur yang lebih kompleks. Penulis berharap dengan adanya system ini dapat membantu menyelesaikan permasalahan sampah.

## 2. TINJAUAN PUSTAKA

### 2.1 Computer Vision

*Computer Vision* yang juga dikenal sebagai *Machine Vision* dijelaskan [9] adalah disiplin ilmu yang memungkinkan mesin belajar cara "melihat" dan merupakan bidang aplikasi penting dari teknologi pembelajaran mendalam, yang banyak digunakan dalam keamanan, inspeksi kualitas industri, dan skenario mengemudi otomatis. Secara khusus, hal ini memungkinkan mesin untuk mengidentifikasi objek dalam gambar atau video yang diambil oleh kamera, mendeteksi lokasi objek, dan melacak objek target, sehingga dapat memahami dan menggambarkan pemandangan dan cerita dalam gambar atau video, untuk mensimulasikan sistem visual otak manusia [10]. Oleh karena itu, *computer vision* juga sering disebut sebagai *machine vision*, dan tujuannya adalah untuk membangun sistem buatan yang dapat "merasakan" informasi dari gambar atau video.

Tugas *Computer Vision* bergantung pada fitur gambar (informasi gambar), dan kualitas fitur gambar sangat menentukan kinerja sistem visi. Metode tradisional biasanya menggunakan Scale-Invariant Feature Transform (SIFT), Histogram of Oriented Gradients (HOG), dan algoritma lain untuk mengekstraksi fitur gambar, lalu menggunakan Support Vector Machine (SVM) dan algoritma pembelajaran mesin lainnya untuk memproses lebih lanjut fitur-fitur ini guna menyelesaikan tugas visual [11].

### 2.2 Convolutional Neural Network

Dalam pengenalan dan klasifikasi gambar, CNN merupakan [12] salah satu model yang paling mapan dan praktis. Model berbasis CNN seperti LeNet, AlexNet, GoogleNet, dan ResNet telah menunjukkan keberhasilan yang signifikan dalam pemrosesan gambar. Oleh karena itu, makalah ini mengusulkan model berbasis CNN untuk mengenali klasifikasikan jenis sampah. Feedforward Neural Network (FNN) merupakan jenis jaringan saraf yang paling sederhana. CNN berevolusi dari FNN dengan mengganti beberapa lapisan yang terhubung penuh dengan lapisan konvolusional dan menyertakan lapisan pengumpulan. CNN yang umum terdiri dari lapisan masukan, lapisan konvolusional, lapisan pengumpulan, lapisan yang terhubung penuh, dan lapisan keluaran.

### 2.3 EfficientNet-B0

Arsitektur EfficientNet-B0 [13] merupakan bagian krusial dari solusi tersebut. EfficientNet-B0 dikenal dengan keseimbangannya antara akurasi dan efisiensi komputasi. CNN dikembangkan dengan fokus pada efisiensi komputasi dan akurasi yang tinggi. Beberapa peran penting yang dimainkan oleh arsitektur EfficientNet-B0 dalam penelitian ini meliputi efisiensi komputasi. Arsitektur ini dirancang untuk memiliki jumlah parameter yang lebih rendah dibandingkan arsitektur lain dengan kinerja yang serupa. Hal ini memungkinkan untuk melatih dan menyebarkan model dengan lebih cepat, bahkan dengan sumber daya komputasi yang terbatas. EfficientNet-B0 merupakan bagian dari serangkaian model Efficient-Net yang dapat diskalakan kompleksitasnya. Model-model dalam seri Efficient-Net memiliki varian seperti B1, B2, hingga B7 dengan tingkat kompleksitas yang meningkat. Hal ini memungkinkan untuk mengadaptasi arsitektur tersebut ke berbagai *dataset* dan kebutuhan komputasi. EfficientNet-B0 juga memiliki lapisan konvolusi yang mampu mengekstraksi fitur-fitur penting dari gambar dengan berbagai tingkat kompleksitas. Hal ini membuatnya cocok untuk mengidentifikasi sampah organik dan non-organik, di mana fitur seperti warna, tekstur, dan bentuk dapat menjadi indikator penting. Arsitektur pada gambar 6. menjadi *baseline* arsitektur EfficientNet yang disebut EfficientNet-B0. Selanjutnya dapat dikembangkan mulai dari EfficientNet-B1 - B7 dengan merubah parameter *scaling*, Seperti yang ditunjukkan pada Tabel 1.

**Tabel 1.** Arsitektur EfficientNet

Stage	Operator	Resolution	channels	Layers
1	Conv3x3	224 x 224	32	1
2	MBCConv1, k3x3	112 x 112	16	1
3	MBCConv6, k3x3	112 x 112	24	2
4	MBCConv6, k5x5	56 x 56	40	2
5	MBCConv6, k3x3	28 x 28	80	3
6	MBCConv6, k5x5	14 x 14	112	3
7	MBCConv6, k5x5	14 x 14	192	4
8	MBCConv6, k3x3	7 x 7	320	1
9	Conv 1x1 & Pooling & FC	7 x 7	1280	1

### 2.4 ResNet-50

ResNet [14] adalah jaringan saraf dalam dengan hampir 50 lapisan yang menggunakan blok residual. Jaringan ini mencapai kinerja tinggi dalam berbagai kompetisi pengenalan gambar. Konsep penambahan lapisan untuk mempelajari fitur kompleks memiliki keterbatasan dalam CNN tradisional. ResNet mengatasi masalah ini dengan memperkenalkan koneksi pintasan yang memungkinkan pemetaan langsung dari *input* ke

*output*. Arsitektur ini banyak digunakan untuk klasifikasi gambar, pelokalan objek, dan deteksi. Jaringan ini juga dapat diperluas ke tugas lain, memberikan keuntungan kedalaman sekaligus mengurangi biaya pemrosesan. Model ResNet seperti ResNet101 dan ResNet152 memiliki lebih sedikit filter dan struktur yang lebih sederhana dibandingkan dengan jaringan VGG. Penulis ResNet memperkenalkan koneksi identitas yang secara langsung menghubungkan *input* lapisan ke *output*-nya. Hal ini memungkinkan lapisan untuk mempelajari pemetaan residual, dilambangkan sebagai  $H(x)$ , di mana  $x$  adalah *input* dan  $F$  adalah *output* dari koneksi identitas. Koneksi ini juga memungkinkan lapisan *nonlinier* untuk mempelajari pemetaan yang berbeda. Arsitektur ResNet [15] mencakup koneksi lewati yang menghubungkan *input* langsung ke *output*, yang memungkinkan pembelajaran pemetaan residual. Ini membantu meringankan masalah gradien yang menghilang dan memungkinkan kinerja yang lebih baik dari lapisan yang lebih dalam. Model ResNet50 khususnya [16] menggunakan arsitektur kemacetan dan terdiri dari lapisan konvolusional dan *pooling*, diulang beberapa kali dengan berbagai ukuran kernel. Arsitektur ResNet50 adalah jaringan saraf dalam yang terdiri dari beberapa lapisan konvolusional dan *pooling*. Berikut ini ringkasan strukturnya:

1. Jaringan dimulai dengan lapisan konvolusional dengan ukuran kernel  $7 \times 7$  dan 64 kernel berbeda. Setiap kernel memiliki ukuran langkah 2, yang menghasilkan satu lapisan.
2. Kemudian diikuti oleh lapisan *max-pooling* yang berisi nilai langkah 2.
3. Berikutnya, ada tiga set lapisan konvolusional:
  - a. Set pertama mencakup tiga lapisan berurutan dengan ukuran kernel  $1 \times 1$ , 64;  $3 \times 3$ , 64; dan  $1 \times 1$ , 256. Set ini diulang tiga kali, menghasilkan sembilan lapisan.
  - b. Set kedua terdiri dari empat lapisan dengan ukuran kernel  $1 \times 1$ , 128;  $3 \times 3$ , 128; dan  $1 \times 1$ , 512. Set ini diulang empat kali, totalnya 12 lapisan.
  - c. Set ketiga mencakup enam lapisan dengan ukuran kernel  $1 \times 1$ , 256;  $3 \times 3$ , 256; dan  $1 \times 1$ , 1024. Set ini diulang enam kali, menghasilkan 18 lapisan.
4. Setelah set ketiga, ada set lain yang terdiri dari tiga lapisan dengan ukuran kernel  $1 \times 1$ , 512;  $3 \times 3$ , 512; dan  $1 \times 1$ , 2048. Set ini diulang tiga kali dan menghasilkan sembilan lapisan.
5. Setelah lapisan konvolusional, lapisan pengumpulan rata-rata diterapkan.
6. Terakhir, ada lapisan yang terhubung penuh dengan 1000 node, diikuti oleh fungsi *softmax*, yang menghasilkan satu lapisan

### 3 METODE PENELITIAN

#### 3.1 Jenis, Sifat, dan Pendekatan Penelitian

Jenis penelitian ini dapat dikategorikan sebagai penelitian eksperimental dengan pendekatan komputasional. Peneliti akan melakukan serangkaian eksperimen dengan menggunakan data gambar sampah untuk membandingkan kinerja dua arsitektur CNN yang populer, yaitu EfficientNet-B0 dan ResNet-50, dalam tugas klasifikasi. Selanjutnya sifat dari penelitian ini eksperimental memungkinkan peneliti untuk memanipulasi variabel-variabel tertentu (misalnya, *hyperparameter*, teknik augmentasi data) dan mengamati dampaknya terhadap hasil. Sifat Penelitian ini akan menghasilkan data numerik yang dapat diukur dan dianalisis secara statistik, seperti akurasi, presisi, *recall*, dan waktu komputasi. Pendekatan Penelitian ini akan mengikuti langkah-langkah berikut: Pengumpulan Data, *Preprocessing* Data, Pembuatan Model, Pelatihan Model, Evaluasi Model, Analisis Hasil.

#### 3.2 Metode Pengumpulan Data

Pengumpulan data dilakukan untuk mendapatkan *dataset* gambar sampah yang diperlukan dalam penelitian klasifikasi. *Dataset* yang digunakan merupakan *dataset public* "Waste Classification Data" yang diperoleh dari platform Kaggle dengan link "<https://www.kaggle.com/datasets/techsash/waste-classification-data>". *Dataset* berikut ini dipilih karena memiliki kualitas gambar yang baik dan telah terorganisir dengan kategori yang sesuai untuk tujuan penelitian klasifikasi sampah organik dan *recyclable*.

#### 3.3 Perbandingan dengan Penelitian Terdahulu

##### 3.3.1 Perbandingan dengan Penelitian pada *Dataset* yang Sama:

1. Penelitian oleh [17], yang menggunakan *dataset* yang sama, melaporkan akurasi yang lebih tinggi yaitu 98.92%. Perbedaan signifikan ini kemungkinan besar disebabkan oleh metodologi *preprocessing* yang berbeda secara fundamental. Sunardi menerapkan konversi *grayscale* dan *resize* gambar ke ukuran yang jauh lebih kecil ( $50 \times 50$  piksel) dengan argumen bahwa model yang lebih sederhana dan *preprocessing* yang tepat lebih efektif untuk *dataset* ini dan dapat menghindari *overfitting*. Sebaliknya, penelitian ini menggunakan gambar berwarna dengan resolusi lebih tinggi ( $224 \times 224$  piksel) dan arsitektur yang lebih kompleks.
2. Penelitian oleh [18] juga menggunakan *dataset* yang sama dan melaporkan akurasi 80.88% dengan model CNN kustom lima lapis. Hasil penelitian ini (88.62%) secara signifikan mengungguli hasil Nnamoko yang dengan jelas menunjukkan keunggulan penggunaan arsitektur *transfer learning*

(ResNet-50) yang lebih dalam dan telah dilatih sebelumnya dibandingkan membangun model sederhana dari awal.

### 3.3.2 Perbandingan dengan Penelitian yang Menggunakan Arsitektur Serupa:

1. Penelitian oleh [8] melaporkan akurasi 98.95% menggunakan ResNet50V2. Meskipun arsitektur dasarnya serupa, versi "V2" dari ResNet-50 memiliki modifikasi internal yang dapat meningkatkan performa. Akurasi mereka yang sangat tinggi menunjukkan bahwa variasi arsitektur dan parameter pelatihan dapat memberikan hasil yang superior.
2. Penelitian oleh [4] juga menggunakan ResNet-50 sebagai bagian dari sistem terpadu mereka dan mencapai akurasi di atas 93% pada berbagai *dataset*. Namun, tujuan mereka lebih kompleks (klasifikasi multi-kelas dan deteksi objek), sehingga perbandingan langsung menjadi kurang relevan.

### 3.3.3 Perbandingan dengan Penelitian yang Menggunakan Metode Berbeda:

1. Penelitian oleh [19] mencapai akurasi 92.6% pada *dataset* TrashNet dengan arsitektur hibrida MLH-CNN yang mereka usulkan.
2. Penelitian oleh [20] mencapai akurasi 92.43% dalam kondisi *real-time*. Fokus utama mereka adalah pada kecepatan dan penerapan di dunia nyata dengan *dataset* kustom.

## 3.4 Metode Analisis Data

Tahapan analisis data merupakan proses sistematis untuk mentransformasikan data mentah mejadi informasi yang bermakna. Penelitian ini menerapkan metodologi analisis komprehensif untuk mengevaluasi performa model EfficientNet-B0 dan ResNet-50 dalam klasifikasi jenis sampah menggunakan arsitektur CNN dengan pendekatan *transfer learning*. Metodologi analisis data yang diimplementasikan meliputi tahapan-tahapan sebagai berikut:

### 3.4.1 Akuisisi dan Preprocessing Dataset

1. Koleksi *Dataset*: Penelitian ini menggunakan *dataset* klasifikasi sampah yang diperoleh dari platform Kaggle dengan spesifikasi sebagai berikut:
  - a. Kelas O (Organic/Organik): 12.565 sampel data latih, 1.401 sampel data uji
  - b. Kelas R (Recyclable/Dapat Didaur Ulang): 9.999 sampel data latih, 1.112 sampel data uji
  - c. Total *dataset*: 22.564 sampel data latih, 2.513 sampel data uji
2. Tahap *Preprocessing* Data:
  - a. Standardisasi dimensi citra menjadi 224×224 piksel sesuai dengan *input requirement* model *pre-trained*
  - b. Normalisasi nilai piksel melalui *rescaling* dengan faktor 1./255 untuk optimalisasi konvergensi
  - c. Partisi data latih dengan *validation split ratio* 20% menghasilkan 18.052 sampel *training* dan 4.512 sampel validasi.
3. Implementasi Augmentasi Data: Penerapan teknik augmentasi pada *dataset training* untuk meningkatkan generalisasi model, meliputi:
  - a. Rotasi citra dengan *range* 30 derajat (*rotation\_range=30°*)
  - b. Translasi horizontal dan vertikal dengan rasio 0.2 (*width\_shift\_range=0.2, height\_shift\_range=0.2*)
  - c. Transformasi *shear* dengan *range* 0.2 (*shear\_range=0.2*)
  - d. Pembesaran/pegecilan citra dengan *zoom\_range=0.2*
  - e. Penyesuaian kecerahan dengan *brightness\_range=[0.5, 1.5]*
  - f. *Horizontal flipping* untuk variasi orientasi
  - g. Bangun model menggunakan arsitektur EfficientNet-B7 dan ResNet-50. Pilih versi arsitektur EfficientNet-B7 dan ResNet-50 sebagai basis komparasi

### 3.4.2 Konfigurasi Parameter Eksperimen

1. Spesifikasi Parameter Utama:
  - a. Dimensi *input* citra: 224×224×3 *channels*
  - b. Ukuran *batch*: 32 sampel per iterasi
  - c. Maksimum *epochs*: 10 dengan mekanisme *early stopping*
  - d. *Random seed*: 42 untuk memastikan *reproducibility* eksperimen
2. *Grid Search Hyperparameter*:
  - a. Arsitektur model: ['efficientnet', 'resnet']
  - b. *Learning rate*: [ $1 \times 10^{-3}$ ,  $1 \times 10^{-4}$ ]

- c. *Batch size*: [32]

### 3.4.3 Desain dan Pelatihan Model

- 1 Implementasi *Transfer Learning*:
  - a. EfficientNet-B0: Menggunakan *pre-trained weights* dari *ImageNet* dengan *fine-tuning* seluruh *layer*
  - b. ResNet-50: Menggunakan *pre-trained weights* dari *ImageNet* dengan *fine-tuning* seluruh *layer*
  - c. Custom CNN: Model dari awal (*from scratch*) sebagai *baseline* pembandingan
- 2 Arsitektur Model Terpadu:
  - a. Base model (*pre-trained*) + *GlobalAveragePooling2D* layer
  - b. Fully connected layers: 512 units (*ReLU* activation) → *Dropout*(0.5) → 256 units (*ReLU* activation) → *Dropout*(0.3)
  - c. Output layer: 2 units dengan *softmax* activation untuk klasifikasi biner
- 3 Strategi Pelatihan Model:
  - a. Optimizer: Adam dengan *learning rate* adaptif
  - b. Fungsi loss: *Categorical crossentropy*
  - c. Metrik evaluasi: *Accuracy*, *Precision*, *Recall*
  - d. Callbacks: *EarlyStopping* (*patience*=5), *ReduceLROnPlateau* (*factor*=0.2), *Model Checkpoint*

### 3.4.4 Metodologi Evaluasi Model

1. Metrik Performa Kuantitatif:
  - a. *Accuracy*: Rasio prediksi benar terhadap total prediksi
  - b. *Precision*:  $\text{True Positive} / (\text{True Positive} + \text{False Positive})$
  - c. *Recall*:  $\text{True Positive} / (\text{True Positive} + \text{False Negative})$
  - d. *F1-Score*: *Harmonic mean* dari *precision* dan *recall*
  - e. *Confusion Matrix*: Matriks kontingensi untuk analisis *error classification*
2. Analisis Komparatif Model:
  - a. Perbandingan *validation accuracy* antar konfigurasi model
  - b. Evaluasi *training time* dan efisiensi komputasi
  - c. Pengukuran *inference time* per *batch*
  - d. Analisis *memory utilization*

### 3.4.5 Desain Eksperimen dan Skenario Pengujian

1. *Grid Search Systematic Evaluation*

Implementasi *systematic comparison* terhadap 4 konfigurasi model:

  - a. EfficientNet-B0 dengan *learning rate*  $1 \times 10^{-3}$
  - b. EfficientNet-B0 dengan *learning rate*  $1 \times 10^{-4}$
  - c. ResNet-50 dengan *learning rate*  $1 \times 10^{-3}$
  - d. ResNet-50 dengan *learning rate*  $1 \times 10^{-4}$
2. Analisis *Transfer Learning* versus *From Scratch*
  - a. *Comparative analysis* antara model *transfer learning* dan model CNN *from scratch*
  - b. Evaluasi *convergence velocity* dan *final performance metrics*
  - c. *Assessment* efektivitas *pre-trained weights* dalam domain klasifikasi sampah
3. *Impact Assessment Data Augmentation*
  - a. *Comparative study* model dengan dan tanpa teknik augmentasi data
  - b. Kuantifikasi *improvement* yang diperoleh dari *augmentation techniques*
  - c. Analisis mitigasi *overfitting phenomena*
4. *Performance Benchmarking Inference*
  - a. *Measurement inference latency* per-*batch* untuk setiap arsitektur model
  - b. *Comparative analysis computational efficiency*: EfficientNet-B0:  $\approx 0.146$  detik per-*batch*, ResNet-50:  $\approx 0.179$  detik per-*batch*, Custom CNN:  $\approx 0.102$  detik per-*batch*

### 3.4.6 Visualisasi Data dan Pelaporan Hasil

1. *Training History Visualization*: Kurva *accuracy*, *loss*, *precision*, dan *recall* selama proses pelatihan
2. *Confusion Matrix Heatmap*: Representasi visual untuk analisis *error classification pattern*

3. *Metrics Comparison Charts*: Diagram batang untuk *precision*, *recall*, *F1-score* per kategori
4. *Model Performance Comparison*: *Comparative visualization accuracy* dan *training duration*
5. *Augmentation Effect Analysis*: Visualisasi dampak *before/after data augmentation*

### 3.4.7 Kriteria Seleksi Model Optimal

Penentuan model terbaik didasarkan pada hierarki kriteria evaluasi sebagai berikut:

1. Kriteria Primer: *Validation accuracy* sebagai indikator utama performa generalisasi
2. Kriteria Sekunder: *Test accuracy*, *precision*, dan *recall* sebagai metrik konfirmasi
3. Kriteria Tersier: *Training duration* dan *inference speed* sebagai pertimbangan efisiensi komputasi

## 3.5 Alur Penelitian

Pada penelitian ini terdiri dari lima tahap utama seperti pada Gambar 1, dengan rincian alur sebagai berikut:

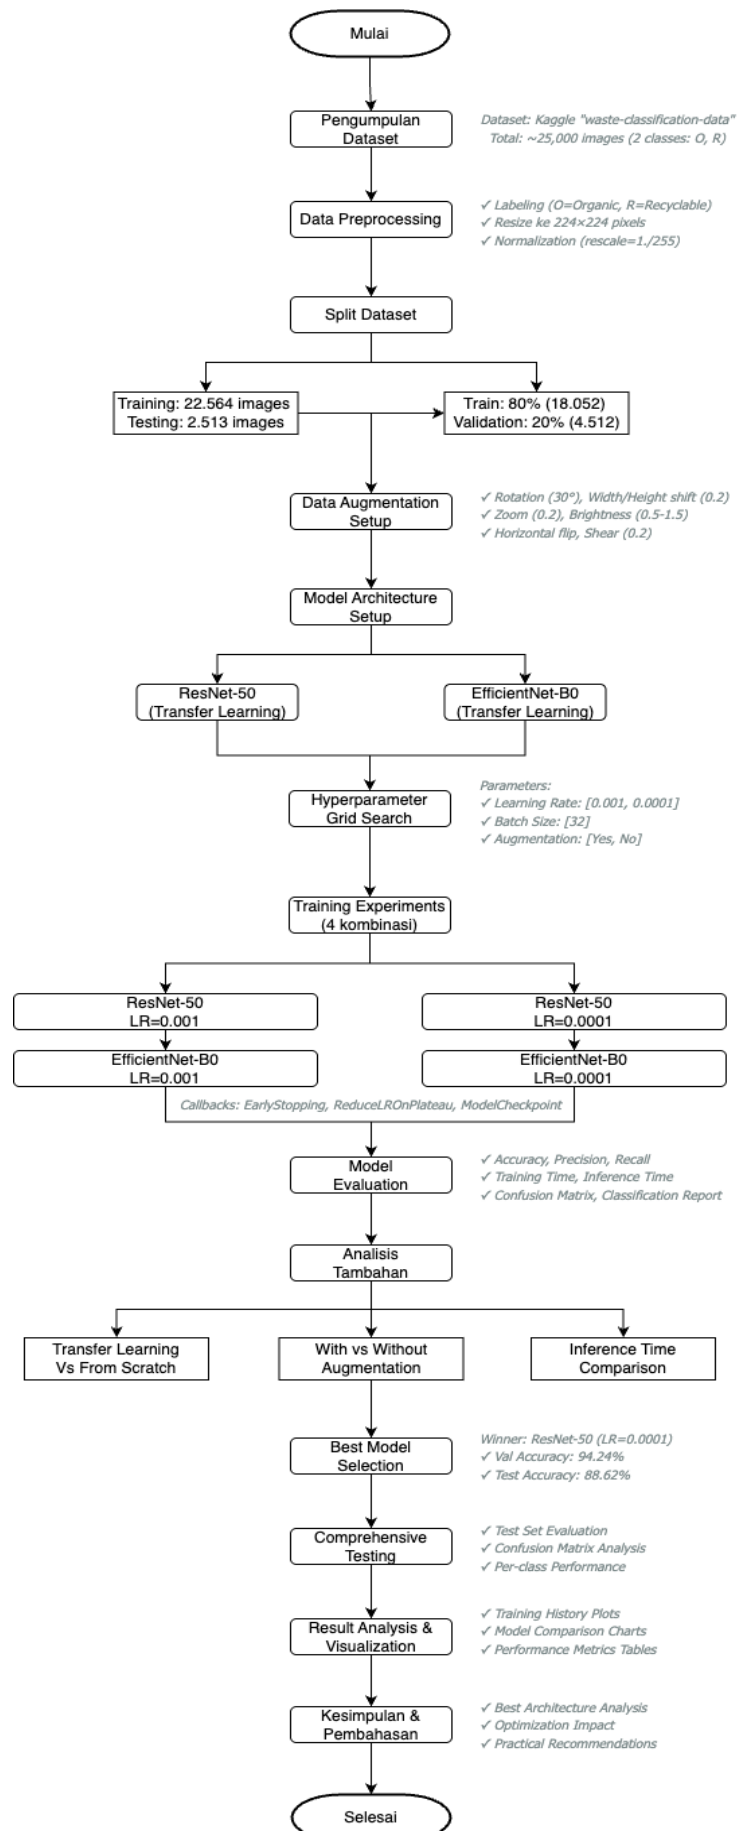
### 3.5.1 Pengumpulan *dataset*

Gambar berwarna barang limbah yang diambil di titik penerimaan di lingkungan tempat pembuangan akhir, Gambar dirilis dalam resolusi 524x524. Label yang diterapkan pada gambar mewakili jenis bahan yang ada, namun penyempurnaan lebih lanjut dari pelabelan dapat dilakukan mengingat ukuran kumpulan data yang sedang (misalnya, membagi kelas plastik menjadi komponen transparan dan buram).

### 3.5.2 *Preprocessing*

Pada tahap ini, terdapat beberapa proses yang dilakukan yaitu mulai dari *labeling*, *resize*, lalu melakukan *splitting* data sehingga bisa dilanjutkan kedalam proses selanjutnya yaitu membuat scenario CNN.

1. *Labeling*  
Pemberian label juga dilakukan pada data gambar sampah yang telah dikumpulkan, kemudian diberi label sesuai dengan informasi gambar.
2. *Proses Resize*  
Proses *resize* dilakukan karena *dataset* yang sudah dikumpulkan tidak memiliki ukuran yang sama dan ukuran citra yang terlalu besar. *Resize* juga bertujuan untuk menyesuaikan ukuran citra terhadap ukuran data masukan *system*.
3. *Split data*  
Berdasarkan label yang diusulkan, jumlah gambar adalah sebagai berikut: Karton, Bahan Organik Makanan, Kaca, Logam, Sampah Lain-lain, Kertas, Plastik, Sampah Tekstil, Tumbuhan.
4. CNN model  
Skenario CNN Karena jenis penelitian ini bersifat eksperimen maka alur penelitian ini disediakan langkah *scenario*. Sebelum peneliti memulai tahap *scenario* ada beberapa tahap sebelumnya yang dilakukan. Salah satu tahapanya adalah menyiapkan data citra dengan *preprocessing* sebagai data *training* dan evaluasi. Untuk dapat mengetahui performa dari peningkatan kualitas citra, maka dilakukan 2 skenario menggunakan algoritma CNN yaitu. ResNet-50 dan EfficientNet-B0.
5. *Training*  
Setelah menentukan scenario yang ada yaitu *transfer learning* menggunakan ResNet-50 dan EfficientNet-B0 kita mulai melakukan percobaan menggunakan *dataset* gambar sampah yang telah dipersiapkan sebelumnya. *Training* data bertujuan untuk melatih skenario yang ada sehingga saat tahap evaluasi dapat menghasilkan nilai akurasi yang tinggi.
6. Analisis dan pembahasan  
Tahap ini merupakan tahap untuk melakukan evaluasi berdasarkan tahap pelatihan menggunakan EfficientNet-B0 dan ResNet-50. Ada dua evaluasi yang dilakukan, yaitu mengetahui performa penerapan arsitektur Resnet-50 dan EfficientNet-B0 pada tahap peningkatan kualitas citra yang diterapkan pada CNN, selanjutnya membandingkan akurasi dari arsitektur EfficientNet-B0 dan ResNet-50 pada peningkatan kualitas citra.



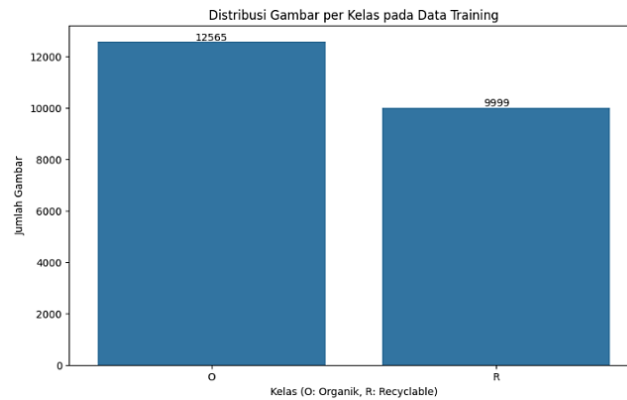
Gambar 1. Bagan Alur Penelitian



## 4. HASIL DAN PEMBAHASAN

### 4.1 Hasil Pengumpulan dan Persiapan Data

Tahap pertama adalah memahami karakteristik *dataset* yang digunakan. Analisis ini bertujuan untuk mengidentifikasi distribusi kelas dalam data *training* yang penting untuk mengetahui apakah terdapat ketidakseimbangan (*imbalance*) jumlah. Gambar 2 merupakan perbandingan antara dua kelas.

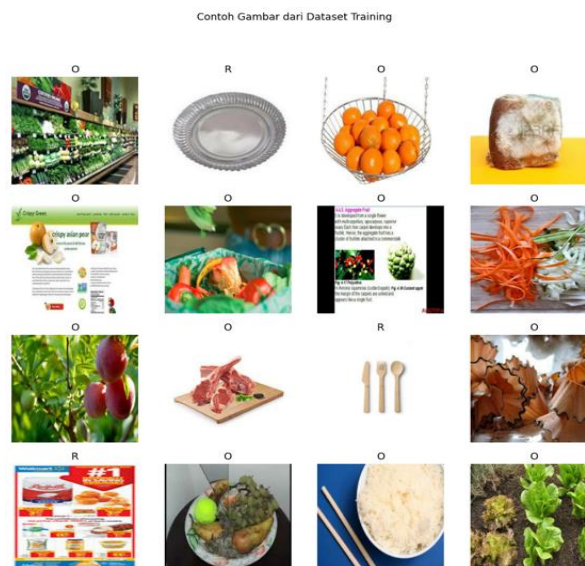


**Gambar 2.** Analisis Distribusi Kelas (Data *Imbalance*)

Berdasarkan visualisasi, *dataset training* terdiri dari 12.565 gambar untuk kelas Organik (O) dan 9.999 gambar untuk kelas Daur Ulang (R). Terdapat sedikit ketidakseimbangan data, di mana jumlah gambar organik lebih banyak daripada gambar daur ulang. Ketidakseimbangan ini perlu diperhatikan karena dapat memengaruhi kinerja model, meskipun dalam kasus ini perbedaannya tidak terlalu ekstrem.

### 4.2 Persiapan dan Visualisasi Data

Setelah memahami data, langkah selanjutnya adalah mempersiapkan data agar siap digunakan untuk melatih model. Proses ini menggunakan `tf.data.Dataset` untuk efisiensi memori dan kecepatan. Selain itu, beberapa contoh gambar dari *dataset* ditampilkan untuk memberikan gambaran visual mengenai data yang akan dipelajari oleh model. Gambar 3 adalah contoh dari *dataset training* yang mewakili kedua kelas.



**Gambar 3.** Contoh Gambar dari *Dataset Training*


Visualisasi ini mengonfirmasi bahwa data telah dimuat dengan benar. Terlihat variasi gambar yang beragam untuk setiap kelas, seperti berbagai jenis buah dan sayuran untuk kelas Organik (O) dan berbagai jenis kemasan atau benda non-organik untuk kelas Daur Ulang (R).

### 4.3 Perbandingan Kinerja Arsitektur Model

Eksperimen ini bertujuan untuk membandingkan dua arsitektur *transfer learning* yang populer, yaitu EfficientNetB0 dan ResNet50, untuk menentukan mana yang memberikan performa terbaik pada tugas

klasifikasi sampah ini. Fungsi `build_model` digunakan untuk membangun model, dan sebuah loop dijalankan untuk melatih dan mengevaluasi kedua arsitektur.

Perbandingan kinerja diukur berdasarkan tiga metrik utama: akurasi (validasi dan tes), waktu pelatihan, dan kompleksitas model (jumlah parameter), pada Gambar 4.



**Gambar 4.** Perbandingan Kinerja Arsitektur

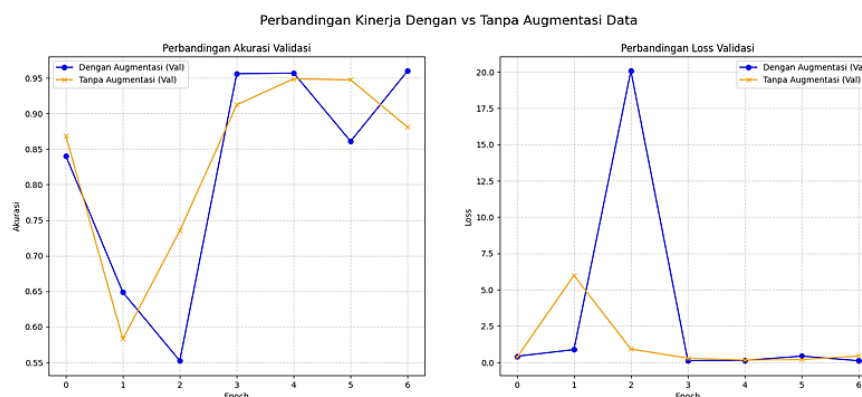
Berdasarkan hasil pengujian, model EfficientNetB0 menunjukkan performa yang lebih unggul dibandingkan ResNet50 dalam hal akurasi dan efisiensi. EfficientNetB0 mencapai akurasi validasi sebesar 96.01% dan akurasi pengujian sebesar 93.71%, sedikit lebih tinggi dibandingkan ResNet50 yang memperoleh akurasi validasi 95.86% dan akurasi pengujian 92.44%. Perbedaan ini menunjukkan bahwa EfficientNetB0 memiliki kemampuan generalisasi yang lebih baik terhadap data yang belum pernah dilihat sebelumnya, menjadikannya model yang lebih andal dalam konteks klasifikasi gambar pada dataset yang digunakan.

Dari segi efisiensi komputasi, EfficientNetB0 juga terbukti lebih unggul dengan waktu pelatihan hanya 24.98 menit, jauh lebih cepat dibandingkan ResNet50 yang memerlukan 39.06 menit. Selain itu, kompleksitas model EfficientNetB0 juga jauh lebih rendah dengan 4.84 juta parameter, sedangkan ResNet50 memiliki 24.77 juta parameter. Hal ini menunjukkan bahwa EfficientNetB0 tidak hanya memberikan akurasi yang lebih baik, tetapi juga menawarkan efisiensi yang tinggi baik dari sisi waktu maupun sumber daya komputasi, sehingga lebih cocok digunakan untuk implementasi pada perangkat dengan keterbatasan daya pemrosesan. Berdasarkan akurasi yang lebih tinggi, waktu pelatihan yang lebih cepat, dan jumlah parameter yang jauh lebih sedikit, EfficientNetB0 dipilih sebagai arsitektur terbaik untuk tugas ini.

#### 4.4 Analisis Dampak Augmentasi

Eksperimen ini dilakukan untuk mengukur efektivitas teknik augmentasi data pada arsitektur terbaik (EfficientNet-B0). Augmentasi data adalah proses memodifikasi gambar *training* secara artifisial (misalnya, rotasi, *zoom*) untuk meningkatkan variasi data dan membantu model melakukan generalisasi lebih baik.

Hasil Perbandingan Dengan vs Tanpa Augmentasi, Perbandingan dilakukan dengan melatih model EfficientNetB0 dengan dan tanpa lapisan augmentasi, bisa dilihat pada Gambar 5.



**Gambar 5.** Perbandingan Kinerja Dengan vs Tanpa Augmentasi Data

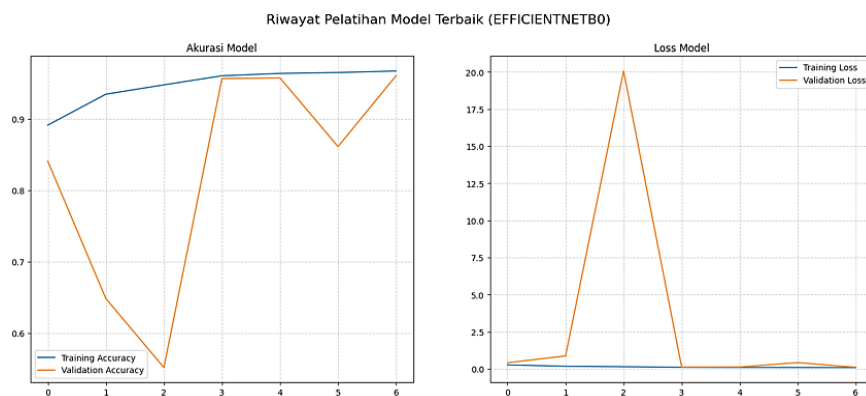
1. Grafik Akurasi Validasi (kiri): Model dengan augmentasi (biru) menunjukkan kurva yang lebih stabil dibandingkan model tanpa augmentasi (oranye). Meskipun akurasi puncak keduanya mirip, model dengan augmentasi cenderung tidak terlalu overfit pada data *training*.

2. Grafik *Loss* Validasi (kanan): Model dengan augmentasi (biru) memiliki nilai *loss* yang lebih rendah dan lebih stabil setelah beberapa *epoch* awal. Lonjakan *loss* yang tinggi pada *epoch* ke-2 menunjukkan bahwa model sedang belajar dari data yang lebih sulit (hasil augmentasi), yang pada akhirnya menghasilkan model yang lebih *robust*.
3. Akurasi pada Data Tes:
  - a. Dengan Augmentasi: 93.71%
  - b. Tanpa Augmentasi: 90.49%

Augmentasi data terbukti efektif, meningkatkan akurasi pada data tes sekitar 3.22%. Ini menunjukkan bahwa augmentasi berhasil meningkatkan kemampuan generalisasi model, membuatnya lebih andal dalam mengenali gambar-gambar baru yang belum pernah dilihat sebelumnya.

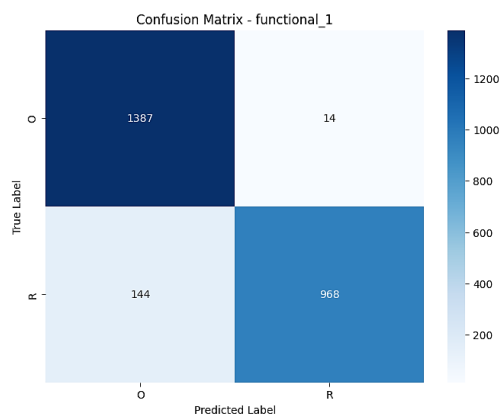
#### 4.5 Evaluasi Akhir Model Terbaik

Tahap terakhir adalah melakukan evaluasi mendalam terhadap model terbaik yang telah dipilih, yaitu EfficientNetB0 yang dilatih dengan augmentasi data. Grafik menunjukkan bagaimana akurasi dan *loss* model berubah selama proses pelatihan pada data *training* dan data validasi, bisa dilihat pada Gambar 6.



**Gambar 6.** Riwayat Pelatihan Model Terbaik (EfficientNet-B0)

1. Akurasi Model (kiri): Akurasi *training* (biru) terus meningkat dan mendekati 100%, sementara akurasi validasi (oranye) juga meningkat dan stabil di level yang tinggi (sekitar 96%). Jarak antara kedua kurva tidak terlalu besar, menandakan model tidak mengalami *overfitting* yang parah.
2. *Loss* Model (kanan): *Loss training* (biru) terus menurun, sementara *loss validasi* (oranye) juga menurun setelah lonjakan awal dan kemudian stabil. Ini adalah perilaku yang diharapkan dari proses pelatihan yang baik.
3. *Confusion Matrix* : *Confusion matrix* memberikan rincian performa model untuk setiap kelas. Ini menunjukkan berapa banyak gambar yang diklasifikasikan dengan benar dan berapa yang salah. *Output Visual* pada Gambar 7.



**Gambar 7.** *Confusion Matrix*

Dari total 2.513 gambar di data tes:

1. *True Positive* (Organik): 1.387 gambar organik diprediksi dengan benar sebagai organik.
2. *True Negative* (Daur Ulang): 968 gambar daur ulang diprediksi dengan benar sebagai daur ulang.

3. *False Positive* (Kesalahan Tipe I): 14 gambar organik salah diprediksi sebagai daur ulang.
4. *False Negative* (Kesalahan Tipe II): 144 gambar daur ulang salah diprediksi sebagai organik.

**Tabel 2.** Laporan Klasifikasi

<i>Classification Report</i> (Laporan Klasifikasi)				
	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
O	0.93	0.98	0.95	1401
R	0.97	0.91	0.94	1112
<i>accuracy</i>			0.95	2513
<i>macro avg</i>	0.95	0.94	0.95	2513
<i>Weighted avg</i>	0.95	0.95	0.95	2513

Berdasarkan Tabel 2, model ini sangat baik dalam mengidentifikasi sampah organik (*recall* 98%), tetapi memiliki sedikit lebih banyak kesulitan dalam mengidentifikasi sampah daur ulang (*recall* 91%), di mana 144 item daur ulang salah diklasifikasikan. Namun, secara keseluruhan, akurasi mencapai 95%, yang merupakan hasil yang sangat baik. Contoh hasil prediksi untuk model terbaik bisa dilihat pada Gambar 8. Visualisasi Gambar 8 menunjukkan bagaimana model memprediksi kelas untuk gambar-gambar acak dari data tes.

### 5. KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, serta untuk menjawab pertanyaan pada rumusan masalah, dapat ditarik kesimpulan berdasarkan hasil perbandingan kinerja arsitektur, model EfficientNetB0 terbukti menjadi model dengan performa terbaik. Model ini berhasil mencapai akurasi pada data uji (Akurasi Tes) tertinggi sebesar 93.71% dengan akurasi validasi sebesar 96.01%. Hasil ini menunjukkan bahwa arsitektur EfficientNetB0 lebih unggul dibandingkan ResNet50, yang mencatatkan akurasi tes sebesar 92.44%. Selain unggul dalam akurasi, EfficientNetB0 juga jauh lebih efisien, dengan waktu pelatihan yang lebih cepat (24.98 menit) dan jumlah parameter yang jauh lebih sedikit (4.84 juta). Augmentasi data juga terbukti efektif, meningkatkan akurasi pada data tes sekitar 3.22%. Ini menunjukkan bahwa augmentasi berhasil meningkatkan kemampuan generalisasi model, membuatnya lebih andal dalam mengenali gambar-gambar baru yang belum pernah dilihat sebelumnya.

Berdasarkan hasil penelitian dan keterbatasan yang ditemukan, berikut adalah saran untuk pengembangan penelitian selanjutnya menambah jumlah dan variasi gambar sampah untuk meningkatkan generalisasi model, terutama untuk kelas dengan performa rendah. Mengembangkan model untuk klasifikasi multi-kelas yang lebih granular (plastik, kertas, logam, kaca, organik). Membuat aplikasi *mobile* atau *website* untuk edukasi masyarakat dalam pemilahan sampah.



**Gambar 8.** Contoh hasil prediksi untuk model terbaik

## REFERENSI

- [1] Y. Wang *et al.*, “Understanding machine learning applications in dementia research and clinical practice: a review for biomedical scientists and clinicians,” *Alzheimers Res Ther*, vol. 16, no. 1, p. 175, Aug. 2024, doi: 10.1186/s13195-024-01540-6.
- [2] Y. Ardian Pradana, I. Cholissodin, and D. Kurnianingtyas, “Analisis Sentimen Pemindahan Ibu Kota Indonesia pada Media Sosial Twitter menggunakan Metode LSTM dan Word2Vec,” 2023. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [3] Yuli Nurhanisah, “Indonesia Darurat Sampah Plastik di Laut,” *Indonesia Baik*. Accessed: Oct. 18, 2024. [Online]. Available: <https://indonesiabaik.id/infografis/indonesia-darurat-sampah-plastik-laut>
- [4] Y. Zhou *et al.*, “Optimization of automated garbage recognition model based on ResNet-50 and weakly supervised CNN for sustainable urban development,” *Alexandria Engineering Journal*, vol. 108, pp. 415–427, Dec. 2024, doi: 10.1016/j.aej.2024.07.066.
- [5] W.-L. Mao, W.-C. Chen, C.-T. Wang, and Y.-H. Lin, “Recycling waste classification using optimized convolutional neural network,” *Resour Conserv Recycl*, vol. 164, p. 105132, Jan. 2021, doi: 10.1016/j.resconrec.2020.105132.
- [6] U. K. Lilhore, S. Simaiya, S. Dalal, and R. Damaševičius, “A smart waste classification model using hybrid CNN-LSTM with transfer learning for sustainable environment,” *Multimed Tools Appl*, vol. 83, no. 10, pp. 29505–29529, Sep. 2023, doi: 10.1007/s11042-023-16677-z.
- [7] H. I. Sutomo, “Identification of Organic and Non-Organic Waste with Computer Image Recognition using Convolutional neural Network with Efficient-Net-B0 Architecture,” *Journal of Applied Intelligent System*, vol. 8, no. 3, pp. 320–330, Nov. 2023, doi: 10.33633/jais.v8i3.9064.
- [8] 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.
- [9] C. Che, H. Zheng, Z. Huang, W. Jiang, and B. Liu, “Intelligent Robotic Control System Based on Computer Vision Technology,” 2024.
- [10] S. Kom. , M. Sc. Dr. Eng. Novanto Yudistira, *Deep Learning: Teori, Contoh Perhitungan, dan Implementasi*. Deepublish, 2024.
- [11] A. W. Salehi *et al.*, “A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope,” *Sustainability*, vol. 15, no. 7, p. 5930, Mar. 2023, doi: 10.3390/su15075930.
- [12] J. Li, Z. Yang, and Y. Luo, “Intention Inference for Space Targets Using Deep Convolutional Neural Network,” *Advances in Space Research*, Oct. 2024, doi: 10.1016/j.asr.2024.10.006.
- [13] H. I. Sutomo, “Identification of Organic and Non-Organic Waste with Computer Image Recognition using Convolutional neural Network with Efficient-Net-B0 Architecture,” 2023. [Online]. Available: <https://www.kaggle.com/datasets/techsash/waste-classification-data>.
- [14] R. C. Poonia and H. A. Al-Alshaikh, “Ensemble approach of transfer learning and vision transformer leveraging explainable AI for disease diagnosis: An advancement towards smart healthcare 5.0,” *Comput Biol Med*, vol. 179, p. 108874, Sep. 2024, doi: 10.1016/j.combiomed.2024.108874.
- [15] A. Jahanbakhshi, M. Momeny, M. Mahmoudi, and P. Radeva, “Waste management using an automatic sorting system for carrot fruit based on image processing technique and improved deep neural networks,” *Energy Reports*, vol. 7, pp. 5248–5256, Nov. 2021, doi: 10.1016/j.egy.2021.08.028.
- [16] M. Ali, F. P. P., and D. Salama Abd Elminaam, “A Feature Selection Based on Improved Artificial Hummingbird Algorithm Using Random Opposition-Based Learning for Solving Waste Classification Problem,” *Mathematics*, vol. 10, no. 15, p. 2675, Jul. 2022, doi: 10.3390/math10152675.
- [17] Sunardi, A. Yudhana, and M. Fahmi, “Improving Waste Classification Using Convolutional Neural Networks: An Application of Machine Learning for Effective Environmental Management,” *Revue d’Intelligence Artificielle*, vol. 37, no. 4, pp. 845–855, Aug. 2023, doi: 10.18280/ria.370404.
- [18] N. Nnamoko, J. Barrowclough, and J. Procter, “Solid Waste Image Classification Using Deep Convolutional Neural Network,” *Infrastructures (Basel)*, vol. 7, no. 4, p. 47, Mar. 2022, doi: 10.3390/infrastructures7040047.
- [19] C. Shi, C. Tan, T. Wang, and L. Wang, “A Waste Classification Method Based on a Multilayer Hybrid Convolution Neural Network,” *Applied Sciences*, vol. 11, no. 18, p. 8572, Sep. 2021, doi: 10.3390/app11188572.
- [20] D. Ziouziou, N. Baras, V. Balafas, M. Dasygenis, and A. Stimoniaris, “Intelligent and Real-Time Detection and Classification Algorithm for Recycled Materials Using Convolutional Neural Networks,” *Recycling*, vol. 7, no. 1, p. 9, Feb. 2022, doi: 10.3390/recycling7010009.