



KLASIFIKASI SAMPAH ORGANIK DAN NON ORGANIK MENGGUNAKAN TRANSFER LEARNING

Doly Ilham Saputra Huta Julu^{1*}, Dewi Nurdiah²

¹Fakultas Teknologi Informasi dan Komunikasi Universitas Semarang
Soekarno-HattaTlogosari Semarang 50196, 024-6702757, e-mail: doly.hutajulu96@gmail.com

²Fakultas Teknologi Informasi dan Komunikasi Universitas Semarang
Soekarno-HattaTlogosari Semarang 50196, 024-6702757, e-mail: nurdiyah@usm.ac.id

ARTICLE INFO

History of the article:

Received 13 June 2025

Received in revised form 30 June 2025

Accepted 3 July 2025

Available online 7 July 2025

Keywords:

Klasifikasi sampah, *transfer learning*, *deep learning*, MobileNetV2, CNN.

* Correspondence:

Telepon:
+6285784774600

E-mail:
nurdiyah@usm.ac.id

ABSTRACT

Pengelolaan sampah di Indonesia menghadapi tantangan serius dengan 7,2 juta ton sampah belum terkelola dengan baik dari 202 kabupaten/kota, mencemari lingkungan dan menghambat daur ulang berkelanjutan. Pemilahan sampah organik dan anorganik yang masih dilakukan secara manual rentan terhadap kesalahan manusia dan tidak efisien. Penelitian ini mengembangkan model klasifikasi sampah organik dan anorganik menggunakan metode *transfer learning* dengan tiga arsitektur CNN: VGG16, MobileNetV2, dan ResNet50V2. Dataset diambil dari kaggle *Waste Classification Data* yang telah melalui proses *preprocessing*. Hasil eksperimen menunjukkan bahwa MobileNetV2 unggul dengan akurasi 90,13%, presisi 96,25%, dan F1-Score 87,88%, waktu inferensi 127,76 ms. Arsitektur ini memberikan keseimbangan optimal antara performa tinggi dan efisiensi komputasi, sehingga ideal diterapkan pada perangkat pintar seperti ponsel dan sistem IoT dalam konteks manajemen sampah perkotaan. Penelitian ini menegaskan efektivitas *transfer learning* dalam membangun sistem klasifikasi sampah yang cerdas dan efisien untuk mendukung program pemilahan sampah di tingkat rumah tangga dan institusi.

INTRODUCTION

Permasalahan sampah semakin kompleks dan membutuhkan solusi yang tidak hanya efektif tetapi juga berkelanjutan. Berdasarkan data Sistem Informasi Pengelolaan Sampah Nasional dari Kementerian Lingkungan Hidup dan Kehutanan (KLHK) tahun 2022 dari 202 kabupaten/kota di Indonesia terdapat timbunan sampah 7,2 juta ton belum terkelola dengan baik[1]. Sampah yang tidak terkelola ini berpotensi mencemari lingkungan, mengancam kesehatan masyarakat, dan menghambat upaya daur ulang yang berkelanjutan. Terutama jika tidak dilakukan pemilahan antara sampah organik dan anorganik sejak dini.

Sampah organik, seperti sisa makanan dan dedaunan, mudah terurai secara alami, sementara sampah anorganik, seperti plastik, kaca, dan logam, membutuhkan waktu yang lama untuk terurai. Pemilahan ini secara konvensional masih dilakukan secara manual, yang tidak hanya memakan waktu dan tenaga, tetapi juga rentan terhadap kesalahan manusia. Terlebih lagi, klasifikasi sampah sering kali sulit dilakukan secara visual karena bentuk, warna, dan kondisi fisik sampah yang sangat bervariasi[2]. Oleh karena itu, dibutuhkan sistem klasifikasi sampah yang otomatis, cepat, dan akurat sebagai solusi teknologi yang mendukung pengelolaan sampah yang lebih baik.


Dengan kemajuan teknologi kecerdasan buatan, terutama pada bidang *Computer Vision*, penerapan metode *Deep learning* telah menjadi solusi potensial dalam menangani klasifikasi berbasis citra[3][4][5]. Salah satu algoritma utama dalam bidang ini adalah *Convolutional Neural Network* (CNN[6][7]), yang terbukti efektif dalam mengenali pola visual melalui proses pembelajaran fitur dari data gambar [8]. Namun demikian, pelatihan model CNN dari awal membutuhkan jumlah data yang besar dan distribusi yang seimbang agar performa model dapat diandalkan[9]. Dalam konteks klasifikasi sampah, tantangan muncul ketika jumlah data pelatihan terbatas dan distribusi kelas tidak merata[10][11].

Untuk mengatasi kendala tersebut, pendekatan *transfer learning* digunakan dalam penelitian ini. *Transfer learning* memungkinkan pemanfaatan model pra-latih (*pre-trained*) seperti VGG16, MobileNetV2, dan ResNet50V2 yang sebelumnya telah dilatih pada dataset besar seperti ImageNet. Model ini kemudian disesuaikan (*fine-tuning*) untuk mengenali dua kelas utama dalam dataset gambar sampah, yaitu organik dan anorganik. Serta menggunakan teknik augmentasi data untuk memperluas variasi data pelatihan, yang telah terbukti efektif dalam meningkatkan performa model CNN[12]. Pendekatan ini sangat berguna dalam kondisi dataset terbatas dan mempercepat proses pelatihan serta meningkatkan akurasi model.

Penelitian ini akan membandingkan kinerja tiga arsitektur CNN pra-latih (VGG16, MobileNetV2, dan ResNet50V2) dalam klasifikasi sampah pada satu dataset yang terdiri dari 2.528 gambar. Selain itu, teknik augmentasi data juga diterapkan untuk meningkatkan keragaman data pelatihan. Diharapkan hasil dari penelitian ini dapat memberikan kontribusi terhadap pengembangan sistem klasifikasi otomatis yang mendukung pengelolaan sampah yang lebih efisien dan berbasis teknologi kecerdasan buatan.

RESEARCH METHODS

Penelitian ini bertujuan untuk mengembangkan model klasifikasi sampah organik dan anorganik menggunakan teknik *transfer learning* dengan arsitektur *Convolutional Neural Network* (CNN).



Gambar 1. Diagram Alur Penelitian


Gambar 1 menunjukkan alur metodologi penelitian secara sistematis. Penelitian dimulai dengan pengumpulan dataset *Waste Classification Data* dari Kaggle, dilanjutkan dengan tahap *preprocessing* yang meliputi normalisasi dan augmentasi data. Selanjutnya, proses dilakukan

melalui pembangunan model menggunakan tiga arsitektur CNN (VGG16, MobileNetV2, dan ResNet50V2) dengan pendekatan *transfer learning*. Ketiga model tersebut kemudian dilatih dengan parameter yang telah ditentukan (learning rate 0,0001, epoch 50, batch size 32) menggunakan *optimizer* Adam dan *binary crossentropy* sebagai fungsi *loss*. Proses validasi dilakukan selama pelatihan dengan teknik *early stopping* untuk mencegah *overfitting*. Evaluasi performa model menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* untuk menentukan model terbaik yang akan diimplementasikan dalam sistem klasifikasi sampah otomatis.

1. Dataset

Dataset yang digunakan dalam penelitian ini berasal dari Kaggle yaitu "*Waste Classification Data*" (<https://www.kaggle.com/techsash/waste-classification-data>). Kedua dataset ini terdiri dari gambar sampah yang telah dikategorikan menjadi dua kelas, yaitu organik (O) dan anorganik (R). Dataset ini dipilih karena memiliki variasi gambar yang cukup untuk melatih model klasifikasi.

Untuk memastikan model dapat dilatih, divalidasi, dan diuji dengan baik, dataset dibagi menjadi tiga bagian utama: set pelatihan, set validasi, dan set pengujian. Pembagian ini bertujuan untuk melatih model menggunakan data yang cukup, menguji kinerja model selama pelatihan, dan menguji performa model pada data yang belum pernah dilihat sebelumnya. Pembagian untuk masing-masing dataset adalah sebagai berikut:



Gambar 2. Distribusi Gambar Dataset *Waste Classification Data*

Gambar 2 memvisualisasikan distribusi dataset yang digunakan dalam penelitian ini dengan total 26.478 gambar. Dataset dibagi menjadi tiga bagian dengan proporsi 70:15:15 untuk memastikan proses pelatihan dan evaluasi yang komprehensif. Set pelatihan terdiri dari:

- Set pelatihan (18.947 gambar) yang digunakan untuk melatih model dan menyesuaikan parameter bobot.
- Set validasi (5.018 gambar) yang berfungsi sebagai pengawas kinerja model selama proses pelatihan dan membantu dalam penerapan *early stopping*.
- Set pengujian (2.513 gambar) yang digunakan untuk evaluasi final performa model terhadap data yang belum pernah dilihat sebelumnya.

Pembagian ini memastikan bahwa model dapat dilatih dengan data yang cukup, serta diuji dengan data yang belum pernah dilihat sebelumnya. Setelah pembagian dataset, data pelatihan

digunakan untuk melatih model, data validasi untuk memonitor kinerja model selama pelatihan, dan data pengujian untuk menguji model setelah pelatihan selesai.

2. Preprocessing

a. Normalisasi

Seluruh gambar diubah ukurannya menjadi resolusi tetap 224×224 piksel. Kemudian, setiap piksel citra x dinormalisasi dari skala $[0, 255]$ ke skala $[0, 1]$ menggunakan persamaan (1).

$$x' = \frac{x}{255} \quad (1)$$

Dimana:

x : nilai intensitas piksel asli,

x' : nilai piksel setelah normalisasi (rescaling).

Hasil dari proses ini digunakan sebagai input untuk model CNN.

b. Augmentasi

Augmentasi dilakukan untuk memperbanyak dan memvariasikan data pelatihan agar model lebih robust dan menghindari overfitting. Beberapa transformasi augmentasi yang diterapkan antara lain:

- 1) Rotasi: sebesar θ derajat acak.
- 2) Perbesaran/Pengecilan (*Zoom*): sebesar z .
- 3) Flipping horizontal.
- 4) Shaaring: perubahan bentuk geometri.

Rumus augmentasi secara umum dinyatakan dengan transformasi *matriks affine* dalam persamaan (2).

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} a & b \\ c & d \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} t_x \\ t_y \end{bmatrix} \quad (2)$$

di mana:

$\begin{bmatrix} x \\ y \end{bmatrix}$: koordinat piksel asli,

$\begin{bmatrix} x' \\ y' \end{bmatrix}$: koordinat piksel hasil transformasi,

$\begin{bmatrix} t_x \\ t_y \end{bmatrix}$: translasi (pergeseran),

a, b, c, d : parameter skala dan rotasi (untuk rotasi 15°)

$$a = \cos(15^\circ) = 0,9659$$

$$b = -\sin(15^\circ) = -0,2588$$

$$c = \sin(15^\circ) = 0,2588$$

$$d = \cos(15^\circ) = 0,9659$$

3. Transfer learning

Penelitian ini menggunakan pendekatan *transfer learning* dengan memanfaatkan tiga arsitektur model CNN yang telah dilatih sebelumnya (pre-trained), yaitu VGG16, MobileNetV2, dan ResNet50V2. Model dasar di-freeze pada bagian awal dan hanya lapisan akhir (fully connected layers) yang disesuaikan dengan kebutuhan klasifikasi dua kelas, yaitu sampah organik dan anorganik. Secara umum, transformasi input x melalui jaringan CNN dapat dituliskan pada persamaan (3).

$$\hat{y} = f\theta(x') \quad (3)$$

x' : citra yang dinormalisasi,

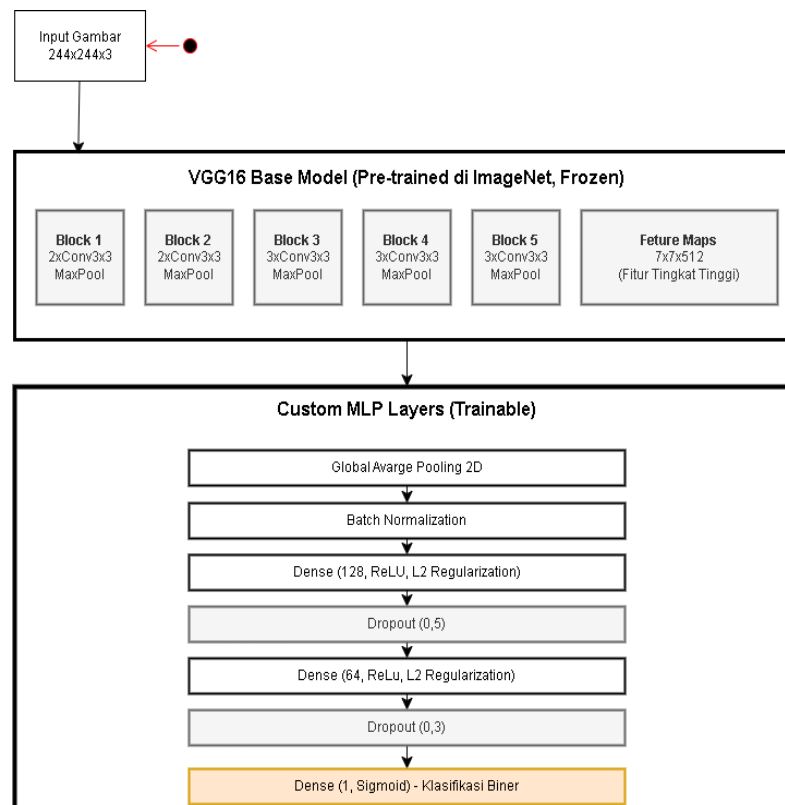
$f\theta$: fungsi non-linear dari model CNN dengan parameter θ ,
 $\hat{y}$: hasil prediksi (probabilitas kelas).

a. Arsitektur model VGG16

VGG16 merupakan arsitektur jaringan *Convolutional Neural Network* (CNN) yang terdiri dari 13 lapisan konvolusi dan 3 lapisan *fully connected*. Model ini menggunakan kernel berukuran kecil (3x3) dan pola berulang yang sederhana, sehingga mudah diimplementasikan namun cukup dalam untuk mengekstraksi fitur yang kompleks dari citra karena telah dilatih sebelumnya menggunakan dataset *ImageNet*, yang terdiri dari lebih dari 14 juta gambar dengan lebih dari 20.000 kategori. Dari jumlah tersebut, sekitar 1.000 kelas digunakan secara umum dalam kompetisi ILSVRC (*ImageNet Large Scale Visual Recognition Challenge*), seperti:

- 1) Kategori hewan: anjing, kucing, gajah, singa, ikan.
- 2) Benda buatan manusia: mobil, pesawat, lemari, laptop, kamera.
- 3) Tanaman: pohon, bunga, buah.
- 4) Aktivitas manusia: menyetir, membaca, berenang.
- 5) Bangunan dan landmark: menara Eiffel, piramida, gedung pencakar langit.

Kategori ini dirancang sedemikian rupa untuk mencakup dunia nyata secara luas dan mendukung pelatihan model yang mampu mengenali objek dari berbagai konteks.



Gambar 3. Arsitektur Model VGG16


Gambar 3 menunjukkan VGG16 digunakan tanpa lapisan *fully-connected* di bagian atas (`include_top=False`) dan bobot dari model pra-latih tersebut difreeze (`trainable=False`) agar hanya berfungsi sebagai *feature extractor*. Gambar input yang digunakan memiliki dimensi 224x224 piksel dengan 3 saluran warna (RGB).

- 1) Base Model VGG16 menghasilkan: Peta fitur dengan dimensi (7, 7, 512) yang kaya akan informasi detail spasial. Ukuran ini adalah dimensi dari *output feature map* yang dihasilkan oleh CNN sebelum masuk ke *fully connected layer*. Format umumnya adalah (*height, width, depth*). Angka 7 pertama menunjukkan tinggi dari *feature map* dengan arti setelah melalui beberapa proses konvolusi dan pooling, citra input direpresentasikan menjadi *grid* dengan tinggi 7 unit. Angka 7 kedua: adalah lebar dari *feature map*. Jadi, hasil ekstraksi fitur berupa representasi spasial berukuran 7x7. Angka 512 adalah jumlah saluran (*channels*) atau disebut juga *depth*, yang menunjukkan jumlah filter konvolusi yang digunakan untuk menangkap berbagai fitur (misalnya tepi, pola, tekstur, bentuk).
- 2) MLP yang Ditingkatkan:
 - a) Layer 1: 124 unit untuk mendeteksi fitur tekstur dan bentuk sampah
 - b) Layer 2: 64 unit untuk integrasi fitur menjadi representasi abstrak
 - c) Menggunakan regularisasi L2 yang lebih kecil (0.0005) untuk generalisasi lebih baik
 - d) Dropout bertingkat (0.5 dan 0.3) untuk mencegah overfitting
 - e) Output Layer: 1 neuron dengan aktivasi sigmoid untuk klasifikasi biner (organik/non-organik).

Model VGG16 dengan modifikasi ini memadukan kekuatan ekstraksi fitur dari jaringan yang telah terbukti handal dengan lapisan klasifikasi yang dioptimalkan khusus untuk tugas klasifikasi sampah. Parameter total: $\pm 14,7$ juta, struktur konvensional dan banyak filter per layer menyebabkan bobot cukup besar.

b. Arsitektur Model MobileNetV2

MobileNetV2 dirancang untuk efisiensi tinggi dengan memanfaatkan *depthwise separable convolution* yaitu teknik efisien dalam CNN yang mengurangi jumlah parameter dan komputasi tanpa mengorbankan akurasi terlalu banyak. Depthwise Separable Convolution terdiri dari dua tahap, pertama *Depthwise Convolution* Setiap filter hanya berlaku pada satu channel saja. Misalnya, untuk gambar RGB (3 *channel*), dilakukan 3 filter berbeda (satu untuk masing-masing R, G, dan B), kedua *Pointwise Convolution* yaitu menggunakan filter 1x1 untuk menggabungkan *output* dari *depthwise convolution* ke dalam *channel* baru, ini mengintegrasikan informasi antar *channel*. Yang memisahkan proses *filtering* dan kombinasi *channel*, serta struktur *inverted residual*. *Inverted residual* block adalah blok jaringan yang digunakan di MobileNetV2, yang membalik proses tradisional pada CNN, biasanya jaringan memperluas dimensi lalu mengurangnya (*contraction* $\rightarrow$ *expansion*). Pada *inverted residual*, justru dilakukan sebaliknya (*ekspansi* $\rightarrow$ *depthwise conv* $\rightarrow$ kontraksi). Tujuannya adalah untuk meningkatkan efisiensi dan menjaga informasi penting dalam dimensi kecil.



Gambar 4. Arsitektur Model MobileNetV2

Gambar 4 menunjukkan MobileNetV2 digunakan tanpa lapisan *fully connected* di bagian atas (`include_top=False`) dan bobot dari model pra-latih tersebut difreeze (trainable=False) agar hanya berfungsi sebagai *feature extractor*. Gambar input yang digunakan memiliki dimensi 224x224 piksel dengan 3 saluran warna (RGB).

- 1) Base Model MobileNetV2 menghasilkan: Peta fitur dengan dimensi (7, 7, 512) yang mempertahankan informasi spasial penting dengan parameter yang jauh lebih sedikit dibandingkan arsitektur CNN konvensional. Ukuran ini adalah dimensi dari *output feature map* yang dihasilkan oleh CNN sebelum masuk ke *fully connected layer*. Format umumnya adalah (*height, width, depth*). Angka 7 pertama menunjukkan tinggi dari *feature map* dengan arti setelah melalui beberapa proses konvolusi dan pooling, citra input direpresentasikan menjadi grid dengan tinggi 7 unit. Angka 7 kedua: adalah lebar dari *feature map*. Jadi, hasil ekstraksi fitur berupa representasi spasial berukuran 7x7. Angka 512 adalah jumlah saluran (*channels*) atau disebut juga *depth*, yang

menunjukkan jumlah filter konvolusi yang digunakan untuk menangkap berbagai fitur (misalnya tepi, pola, tekstur, bentuk).

2) Custom MLP untuk Klasifikasi:

- a) *GlobalAveragePooling2D*: Mereduksi dimensi spasial secara efisien tanpa menambah parameter.
- b) *Batch Normalization*: Menstabilkan proses pelatihan dan mempercepat konvergensi.
- c) *Dense Layer*: 64 neuron dengan aktivasi ReLU untuk interpretasi fitur tingkat tinggi.
- d) *Dropout (0.5)*: Mencegah overfitting dengan menonaktifkan 50% *neuron* secara acak selama pelatihan.
- e) *Output Layer*: 1 neuron dengan aktivasi sigmoid untuk klasifikasi biner (organik/non-organik).

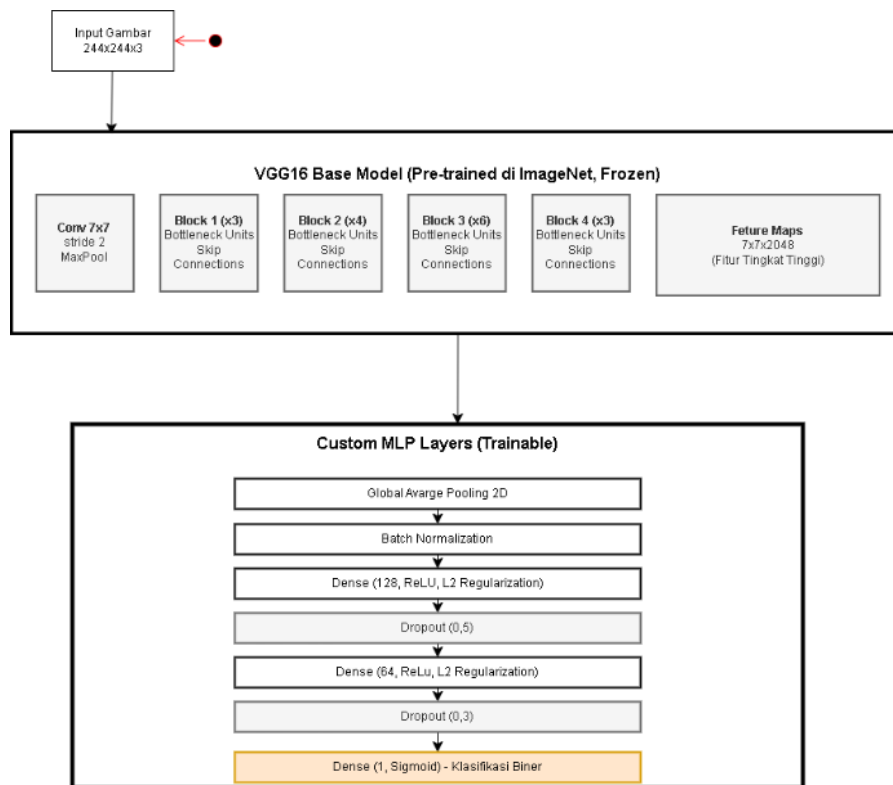
Model MobileNetV2 yang diimplementasikan menggunakan parameter $\alpha=0.75$ dengan parameter total: $\pm 2,6$ juta untuk menghasilkan model yang lebih ringan dan cepat, namun tetap mempertahankan akurasi yang baik karena memanfaatkan bobot pra-latih dari dataset *ImageNet* yang terdiri dari lebih dari 14 juta gambar dengan lebih dari 20.000 kategori seperti yang telah di jelaskan pada model VGG16. Sehingga sangat efisien, cocok untuk deployment pada perangkat dengan sumber daya terbatas.

c. Arsitektur Model ResNet50V2

ResNet50V2 merupakan pengembangan dari ResNet50 yang memperkenalkan *residual connections* atau *skip connections* ini adalah teknik arsitektur yang diperkenalkan oleh ResNet untuk memungkinkan informasi melewati satu atau lebih lapisan dalam jaringan neural, terutama jaringan yang sangat dalam yang memungkinkan aliran gradien tetap terjaga pada jaringan yang sangat dalam. Output dari layer sebelumnya ditambahkan langsung ke *output* layer yang lebih dalam. Ini menciptakan shortcut yang memungkinkan jaringan melompati *layer* tertentu.

Arsitektur ini mengatasi masalah *vanishing gradient*. *Vanishing Gradient* adalah masalah umum dalam pelatihan jaringan neural yang sangat dalam, di mana nilai gradien menjadi sangat kecil ketika dibawa kembali (*backpropagation*) ke layer awal, akibatnya menjadi bobot layer awal sulit diperbarui, jaringan tidak belajar dengan efektif, dan performa model memburuk. Penyebabnya adalah aktivasi seperti *sigmoid/tanh* menyebabkan *gradient* mengecil saat nilai jauh dari nol, *layer* bertumpuk terlalu banyak. Solusi yang bisa digunakan ReLU sebagai fungsi aktivasi, *batch normalization*, dan *residual connections* seperti pada ResNet.

Yang sering terjadi pada jaringan neural yang sangat dalam dengan memungkinkan informasi melewati beberapa lapisan melalui koneksi residual. Dengan total 50 lapisan konvolusional yang disusun dalam blok residual, model ini mampu menangkap fitur yang sangat kompleks dari citra.



Gambar 5. Arsitektur Model ResNet50V2

Gambar 5 menunjukkan ResNet50V2 digunakan tanpa lapisan *fully-connected* di bagian atas (`include_top=False`) dan bobot dari model pra-latih tersebut difreeze (trainable=False) agar hanya berfungsi sebagai *feature extractor*. Gambar input yang digunakan memiliki dimensi 224x224 piksel dengan 3 saluran warna (RGB).

- 1) *Base Model* ResNet50V2 menghasilkan: Peta fitur dengan dimensi (7, 7, 2048) yang sangat kaya akan representasi hierarkis fitur berkat kedalaman jaringan dan koneksi residual yang memungkinkan propagasi informasi yang lebih baik. Ukuran ini adalah dimensi dari *output feature map* yang dihasilkan oleh CNN sebelum masuk ke *fully connected layer*. Format umumnya adalah (*height, width, depth*). Angka 7 pertama menunjukkan tinggi dari *feature map* dengan arti setelah melalui beberapa proses konvolusi dan pooling, citra input direpresentasikan menjadi grid dengan tinggi 7 unit. Angka 7 kedua: adalah lebar dari *feature map*. Jadi, hasil ekstraksi fitur berupa representasi spasial berukuran 7x7. Angka 2048 adalah jumlah saluran (*channels*) atau disebut juga *depth*, yang menunjukkan jumlah filter konvolusi yang digunakan untuk menangkap berbagai fitur (misalnya tepi, pola, tekstur, bentuk).
- 2) MLP untuk Klasifikasi:
 - a) *GlobalAveragePooling2D*: Mereduksi dimensi spasial menjadi vektor fitur 2048-dimensi yang padat informasi.
 - b) *Dense Layer 1*: 128 unit dengan aktivasi ReLU dan regularisasi L2 (0.0005) untuk ekstraksi fitur tingkat tinggi

- c) *Dropout* (0.5): Meningkatkan robustness model dengan mencegah co-adaptasi antar neuron.
- d) *Dense Layer 2*: 64 unit untuk representasi yang lebih kompak namun tetap menjaga informasi diskriminatif.
- e) *Dropout* (0.3): Lapisan dropout kedua untuk mencegah overfitting lebih lanjut.
- f) *Output Layer*: 1 neuron dengan aktivasi sigmoid untuk klasifikasi biner (organik/non-organik).

Model ResNet50V2 menawarkan keseimbangan yang optimal antara akurasi dan kompleksitas komputasi berkat struktur residual yang memungkinkan pelatihan jaringan yang sangat dalam dengan efektif. Parameter digunakan total $\pm 23,5$ juta arsitektur ini unggul dalam klasifikasi citra kompleks dengan detail halus seperti yang diperlukan dalam klasifikasi sampah, sambil mempertahankan kemampuan generalisasi yang baik.

d. Pelatihan Model

Proses pelatihan model dilakukan dengan konfigurasi yang dirancang untuk menghasilkan performa optimal sekaligus menghindari overfitting. Berikut adalah konfigurasi pelatihan yang digunakan:

Tabel 1. Konfigurasi Pelatihan

Parameter	Nilai
<i>Optimizer</i>	Adam
<i>Learning Rate</i>	0,0001
<i>Epoch</i>	50
<i>Batch Size</i>	32
<i>Loss Function</i>	Binary Crossentropy

Tabel 1 merinci parameter pelatihan model dilakukan dengan *batch size* 32 dan jumlah maksimum epoch sebanyak 50. Untuk mencegah *overfitting*, diterapkan teknik *early stopping*, yaitu penghentian pelatihan secara otomatis ketika performa validasi tidak lagi meningkat. Proses *training* menggunakan skema *train-validation-test* split sebesar 70:15:15, di mana 15% data digunakan sebagai validasi untuk memantau kinerja model selama pelatihan berlangsung. Optimasi parameter bobot dilakukan dengan *Adam optimizer*, yang dikenal stabil dan adaptif terhadap dinamika perubahan gradien, dengan nilai learning rate sebesar 0.0001.

Fungsi *loss Binary Crossentropy* digunakan dalam pelatihan model klasifikasi dua kelas (*biner*). Meskipun untuk dua kelas umumnya digunakan *Binary Crossentropy*, namun jika label dikodekan dalam format *one-hot encoding* ([1,0] untuk organik dan [0,1] untuk anorganik), maka *Binary Crossentropy* tetap relevan dan bekerja secara optimal. Fungsi loss ini menghitung perbedaan antara distribusi probabilitas prediksi dengan distribusi sebenarnya, pada persamaan (4).

$$L = - \sum_{i=1}^K y_i \log(\hat{y}_i) \quad (4)$$

Dimana:

y_i : label sebenarnya (0 atau 1),

$\hat{y}_i$: output prediksi dari model.

Loss ini memaksa model untuk semakin mendekati distribusi target yang benar, dan sangat sensitif terhadap kesalahan prediksi probabilistik.

Jumlah total parameter yang digunakan dalam model bergantung pada arsitektur CNN yang digunakan sebagai feature extractor dan penambahan MLP (Multi-Layer

Perceptron) di bagian atas. Berikut estimasi jumlah parameter dari masing-masing model (dalam keadaan `include_top=False` dan `trainable=False`, ditambah MLP custom):

Tabel 2. Total Parameter Model

Model	Parameter(<i>approx</i>)
VGG16	±15 juta
MobileNetV2	±2,6 juta
ResNet50V2	± 23,5 juta

Tabel 2 menyajikan perbandingan jumlah parameter dari ketiga arsitektur CNN yang digunakan. VGG16 memiliki sekitar 15 juta parameter, menunjukkan kompleksitas model yang cukup tinggi dengan lapisan konvolusional yang lebar. MobileNetV2 dengan parameter $\alpha=0,75$ memiliki sekitar 2,6 juta parameter, jauh lebih efisien berkat penggunaan *depthwise separable convolution* yang mengurangi jumlah operasi tanpa mengorbankan kapasitas ekstraksi fitur. ResNet50V2 memiliki parameter terbanyak sekitar 23,5 juta karena struktur residual yang dalam dan kaya. Perbandingan ini penting untuk mengevaluasi efisiensi komputasi dan kebutuhan memori dari masing-masing model, dengan MobileNetV2 menunjukkan efisiensi tertinggi yang sangat bermanfaat untuk implementasi pada perangkat dengan sumber daya terbatas.

4. Evaluasi

Evaluasi model dilakukan untuk mengukur kinerja klasifikasi terhadap dua kelas target, yaitu sampah organik dan anorganik, berdasarkan hasil dari data pengujian. Evaluasi ini mencakup beberapa metrik umum klasifikasi, seperti akurasi, presisi, *recall*, dan *F1-Score*. Selain itu, visualisasi juga dilakukan dengan menggunakan *confusion matrix* untuk melihat seberapa baik model mengklasifikasikan gambar ke dalam kategori yang benar.

a. Metrik Evaluasi

Berikut adalah definisi dan rumus dari masing-masing metrik evaluasi:

1) Akurasi (*Accuracy*)

Akurasi menunjukkan proporsi prediksi yang benar terhadap total jumlah data, dengan rumus pada persamaan (5).

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

2) Presisi (*Precision*)

Presisi mengukur seberapa akurat prediksi positif dari model dengan rumus pada persamaan (6).

$$Presisi = \frac{TP}{TP+FN} \quad (6)$$

3) *Recall* (*Sensitivity*)

Menunjukkan seberapa baik model dapat menemukan semua contoh positif dengan rumus pada persamaan (7).

$$Recall = \frac{TP}{TP+FP} \quad (7)$$

4) *F1-Score*

F1-Score adalah harmonisasi antara presisi dan *recall*, sangat berguna jika terdapat ketidakseimbangan kelas dengan rumus pada persamaan (8).

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (8)$$

Keterangan:

TP (True Positif): Menunjukkan jumlah gambar sampah organik yang berhasil diklasifikasikan dengan benar oleh model sebagai organik.

TN (True Negatif): Jumlah data gambar sampah anorganik yang berhasil diklasifikasikan dengan benar oleh model sebagai anorganik.

FP (False Positif): Menunjukkan jumlah gambar sampah anorganik yang diklasifikasikan dengan salah oleh model sebagai organik.

FN (False Negatif): Menunjukkan jumlah gambar sampah organik yang diklasifikasikan dengan salah oleh model sebagai anorganik.

b. *Confusion Matrix*

Confusion matrix digunakan untuk menunjukkan perbandingan antara label sebenarnya dan hasil prediksi dari model. Matriks ini terdiri dari empat nilai utama (TP, TN, FP, FN) dan membantu dalam mengidentifikasi kesalahan klasifikasi yang dilakukan oleh model terhadap kedua kelas.

Contoh bentuk umum dari confusion matrix dua kelas:

Tabel 3. Contoh Bentuk *Confusion Matrix*


	Prediksi Positif	Prediksi Negatif
Aktual Positif	TP	FN
Aktual Negatif	FP	TN

Tabel 3 menjelaskan struktur dasar confusion matrix yang digunakan untuk evaluasi model klasifikasi biner. Tabel ini menampilkan empat komponen utama: True Positive (TP) yaitu sampel positif yang benar diprediksi positif, True Negative (TN) yaitu sampel negatif yang benar diprediksi negatif, False Positive (FP) yaitu sampel negatif yang salah diprediksi positif, dan False Negative (FN) yaitu sampel positif yang salah diprediksi negatif. Dalam konteks penelitian ini, sampel positif merujuk pada sampah organik dan sampel negatif merujuk pada sampah anorganik. Confusion matrix ini menjadi dasar perhitungan metrik evaluasi seperti akurasi, presisi, recall, dan F1-score yang digunakan untuk membandingkan performa ketiga model.

RESULTS

Sebelum melatih model klasifikasi gambar sampah, dilakukan tahap praproses data guna memastikan kualitas dan konsistensi input. Gambar-gambar yang digunakan berasal dari dataset Kaggle "*Waste Classification Data*", yang memiliki berbagai resolusi dan pencahayaan. Untuk itu, setiap gambar terlebih dahulu diubah ukurannya menjadi dimensi seragam 224x224 piksel. Proses ini penting agar jaringan konvolusional dapat menerima input yang seragam dan menganalisis fitur visual dengan lebih efisien.

Selain *resize*, gambar juga melalui proses normalisasi piksel dari rentang 0-255 menjadi 0-1. Tahapan ini sangat krusial karena memungkinkan model untuk belajar lebih stabil selama proses pelatihan, menghindari gradien yang terlalu besar, serta mempercepat konvergensi model. Gambar berikut menunjukkan perbedaan antara citra asli dan hasil setelah normalisasi:




Gambar 6. Contoh Hasil Normalisasi.

Berikut ini penjelasan dari gambar 6 yang telah dilabeli a, b, c, dan d. Gambar 6a adalah gambar *Original Image* (Anorganik) merupakan gambar asli dari objek anorganik berupa sendok-sendok logam yang belum melalui proses normalisasi. Citra masih memiliki pencahayaan dan warna asli dari proses pengambilan gambar. Gambar 6b adalah gambar *Normalized Image* (Anorganik) merupakan hasil dari normalisasi citra pada objek anorganik. Proses ini memperbaiki kontras, kecerahan, dan keseimbangan warna untuk meningkatkan kualitas visual dan keseragaman antar gambar. Perubahan ini membantu sistem klasifikasi untuk mengenali fitur secara lebih konsisten. Gambar 6c adalah gambar *Original Image* (Organik) merupakan gambar asli dari objek organik berupa wortel. Gambar ini menunjukkan warna dan pencahayaan natural saat pengambilan tanpa modifikasi. Perbedaan intensitas warna dan cahaya dapat menyulitkan model untuk mendeteksi fitur penting. Gambar 6d adalah gambar *Normalized Image* (Organik) gambar telah melalui proses normalisasi, yang mengatur intensitas piksel dan memperbaiki kualitas citra. Warna wortel menjadi lebih tajam dan seragam, serta latar belakang menjadi lebih bersih, membantu meningkatkan akurasi pengenalan dalam sistem klasifikasi berbasis citra.

Setelah tahap preprocessing, dataset dipisahkan menjadi tiga bagian: 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian menjadi set pelatihan (18.947 gambar), set validasi (5.018 gambar), set pengujian (2.513 gambar). Setiap model kemudian dilatih dengan konfigurasi yang sama: menggunakan *optimizer Adam*, *learning rate* sebesar 0.0001, dan *batch size* sebanyak 32. Fungsi *loss* yang digunakan adalah *Binary Crossentropy* karena klasifikasi dilakukan terhadap dua kelas (organik dan anorganik) dengan format *one-hot encoding*, di mana fungsi ini mampu menghitung selisih antara probabilitas prediksi dan label target secara efektif. Pelatihan dilakukan selama maksimal 50 *epoch* dengan penerapan teknik *early stopping* untuk mencegah *overfitting*.

Selama pelatihan berlangsung, performa setiap model dicatat dalam bentuk grafik akurasi dan *loss* terhadap jumlah *epoch*. Grafik berikut menampilkan proses pelatihan ketiga arsitektur CNN (VGG16, MobileNetV2, dan ResNet50V2).



Gambar 7. Grafik Akurasi dan Loss dari Model VGG16, MobileNetV2, dan ResNet50V2 selama proses pelatihan.

Gambar 7 menyajikan visualisasi komparatif performa pelatihan ketiga model CNN dengan parameter *optimizer Adam* (learning rate 0,0001), batch size 32, dan maksimum 50 *epoch*. Grafik sebelah kiri menunjukkan kurva akurasi pelatihan dan validasi, di mana MobileNetV2 mencapai konvergensi lebih cepat pada *epoch* ke-30 dengan nilai akurasi validasi tertinggi 90,13%. VGG16 dan ResNet50V2 menunjukkan tren peningkatan akurasi yang serupa namun dengan nilai akhir sedikit lebih rendah, masing-masing 88,10% dan 88,30%. Grafik sebelah kanan menampilkan kurva *loss* pelatihan dan validasi, di mana ketiga model menunjukkan penurunan yang stabil dengan MobileNetV2 mencapai nilai *loss* validasi terendah. Pola kurva yang tidak menunjukkan gap besar antara pelatihan dan validasi mengindikasikan bahwa ketiga model berhasil menghindari overfitting berkat implementasi dropout, regularisasi L2, dan teknik early stopping yang diterapkan.

Setelah proses pelatihan selesai, model dievaluasi menggunakan data pengujian sebanyak 2.513 gambar. Evaluasi dilakukan menggunakan empat metrik utama: akurasi, presisi, *recall*, dan *F1-Score*. Berikut adalah hasil evaluasi dari ketiga model:


Tabel 4. Perbandingan Kinerja Evaluasi Semua Model dan

Model	Akurasi	Presisi	<i>Recall</i>	<i>F1-Score</i>	Waktu Inferensi (ms)
VGG16	88,10%	91,95%	80,15%	85,63%	130,41
MobileNetV2	90,13%	96,25%	80,25%	88,78%	127,76
RestNet50V2	88,30%	96,80%	76,08%	80,20%	139,68


Tabel 4 menyajikan perbandingan performa dari ketiga model yang telah diimplementasikan, yakni VGG16, MobileNetV2, dan ResNet50V2. Evaluasi dilakukan menggunakan metrik akurasi, presisi, *recall*, *F1-Score*, serta waktu inferensi rata-rata dalam milidetik. Berdasarkan hasil tersebut, MobileNetV2 menunjukkan performa terbaik dengan akurasi sebesar 90,13% dan nilai *F1-Score* tertinggi sebesar 88,78%. Presisi yang dicapai model ini sebesar 96,25%, dengan *recall* sebesar 80,25%, serta waktu inferensi tercepat yaitu 127,76 ms. ResNet50V2 memperoleh presisi tertinggi di antara ketiga model, yaitu sebesar 96,80%, namun *recall* yang diperoleh lebih rendah, yakni 76,08%. Meskipun demikian, akurasi model ini cukup baik yaitu 88,30%, dengan *F1-Score* sebesar 80,20% dan waktu inferensi rata-rata 139,68 ms. Model VGG16 menunjukkan performa yang relatif seimbang dengan akurasi sebesar 88,10%, presisi 91,95%, *recall* 80,15%, *F1-Score* 85,63%, serta waktu inferensi 130,41 ms.

Dari hasil evaluasi tersebut dapat disimpulkan bahwa MobileNetV2 menjadi model paling optimal untuk digunakan dalam sistem klasifikasi citra pada penelitian ini. Model ini mampu memberikan keseimbangan terbaik antara performa klasifikasi dan efisiensi waktu inferensi,


sehingga lebih direkomendasikan untuk implementasi sistem berbasis deep learning yang memerlukan respon cepat.



Gambar 8. Convusion Matrix VGG16



Gambar 9. Convusion Matrix MobileNetV2



Gambar 10. Convusion Matrix RestNet50V2

Gambar 8, 9, dan 10 menampilkan confusion matrix dari ketiga model yang menunjukkan distribusi prediksi benar dan salah. Confusion matrix VGG16 (Gambar 8) menunjukkan model ini mengidentifikasi dengan benar 996 sampel sampah organik dan 1215 sampel anorganik, dengan kesalahan klasifikasi 247 sampel organik sebagai anorganik dan 55 sampel anorganik sebagai organik. MobileNetV2 (Gambar 9) menampilkan performa terbaik dengan benar mengklasifikasikan 997 sampel organik dan 1269 sampel anorganik, dengan jumlah kesalahan klasifikasi yang lebih sedikit yaitu 246 sampel organik sebagai anorganik dan hanya 1 sampel anorganik sebagai organik. ResNet50V2 (Gambar 10) mengidentifikasi dengan benar 943 sampel organik dan 1276 sampel anorganik, dengan 300 sampel organik salah diklasifikasi sebagai anorganik dan 42 sampel anorganik sebagai organik. Dari ketiga confusion matrix ini, terlihat bahwa MobileNetV2 memiliki performa terbaik terutama dalam meminimalisir false positives (sampel anorganik yang salah diklasifikasi sebagai organik).

Tabel 5. Perbandingan Penelitian Terkait Model Klasifikasi Sampah

Peneliti	Model	Akurasi	Dataset	Tahun
Yong L., Ma L., Sun D., Du L. [13]	CNN	67,50%	Dataset lokal TPA	2023
Md. Monirul Islam, Shahriar Hassan, Md. Nasim Akhtar[14]	VGG19	89,02%	<i>Organic & Recyclable Waste</i>	2023
Vieri D, Susanto R, Purwanto E, Ario M [15]	YOLOv8-nano	89%	3.500 gambar sampah terlabel	2024
Penelitian ini	MobileNetV2	90,15%	Kaggle " <i>Waste Classification Data</i> "	2025

Pada Tabel 5 menunjukan perbandingan ini memperkuat efektivitas pendekatan *transfer learning*, khususnya dengan arsitektur MobileNetV2, yang mampu mengungguli hasil dari penelitian sebelumnya. Jika dibandingkan dengan metode CNN konvensional yang digunakan oleh Yong et al. [13], peningkatan akurasi mencapai 22,63%. MobileNetV2 juga sedikit lebih unggul

dari VGG19 yang digunakan oleh Islam et al. [14] dengan selisih akurasi 1,11% dan dari YOLOv8-nano yang digunakan oleh Vieri et al. [15] sebesar 1,13%. Hal ini menegaskan bahwa arsitektur yang lebih ringan seperti MobileNetV2 tidak hanya efisien tetapi juga efektif dalam tugas klasifikasi gambar sampah.

Hasil evaluasi dan perbandingan performa ketiga model menunjukkan bahwa MobileNetV2 berhasil mencapai akurasi tertinggi sebesar 90,13% dalam tugas klasifikasi gambar sampah menjadi organik dan anorganik. Selain itu, model ini mencatatkan nilai *F1-Score* sebesar 88,78% serta presisi tinggi sebesar 96,25%, dengan waktu inferensi tercepat yaitu 127,76 milidetik. Keseimbangan antara performa klasifikasi dan efisiensi waktu inferensi ini menjadi aspek penting dalam konteks pemilahan sampah, khususnya untuk skenario implementasi di dunia nyata yang memerlukan sistem responsif dan akurat.

Jika dibandingkan dengan model lain dalam penelitian ini, VGG16 mencatatkan akurasi sebesar 88,10% dengan *F1-Score* 85,63% dan waktu inferensi 130,41 milidetik, sementara ResNet50V2 memperoleh akurasi sebesar 88,30%, *F1-Score* 80,20%, dan waktu inferensi terlama yaitu 139,68 milidetik. Meski ResNet50V2 memiliki presisi tertinggi, yaitu 96,80%, *recall* model ini lebih rendah dibandingkan MobileNetV2, sehingga MobileNetV2 tetap menjadi pilihan optimal karena menawarkan keseimbangan performa yang lebih baik di seluruh metrik evaluasi.

Jika dibandingkan dengan penelitian sebelumnya, MobileNetV2 memiliki performa yang lebih tinggi. Seperti ditunjukkan pada Tabel 5, model ini mengungguli CNN dari Yong et al. [13] dengan selisih akurasi sebesar 22,63%. Bahkan dibandingkan dengan model-model mutakhir seperti VGG19 [14] dan YOLOv8-nano [15], MobileNetV2 memiliki selisih akurasi berturut-turut sebesar 1,11% dan 1,13%. Ini menunjukkan bahwa pemilihan arsitektur dan pendekatan *transfer learning* memiliki dampak signifikan terhadap akurasi klasifikasi.

Perbedaan ini juga dapat dikaitkan dengan teknik pelatihan model. Dengan *transfer learning*, pelatihan bisa dilakukan dengan lebih sedikit epoch dan data, namun tetap menghasilkan akurasi tinggi. Hal ini berbeda dengan pelatihan dari awal seperti pada CNN yang memerlukan dataset besar dan waktu pelatihan yang lebih panjang.

Implementasi MobileNetV2 sangat menjanjikan untuk penggunaan di dunia nyata. Karakteristiknya yang ringan dan cepat memungkinkan pengaplikasian di perangkat mobile dan sistem edge computing seperti IoT. Misalnya, sistem ini dapat dikembangkan menjadi aplikasi klasifikasi sampah di smartphone atau digunakan dalam smart bin yang otomatis mengklasifikasikan jenis sampah berdasarkan gambar. Pengembangan ini akan sangat membantu dalam mendukung program pemilahan sampah di tingkat rumah tangga dan institusi, sekaligus mengurangi beban pengelolaan sampah di tingkat akhir.

CONCLUSIONS AND RECOMMENDATIONS

Kesimpulan Penelitian ini menunjukkan bahwa penerapan *transfer learning* pada arsitektur *deep learning* dapat memberikan hasil klasifikasi yang akurat dan efisien terhadap sampah organik dan anorganik. Model MobileNetV2 menunjukkan performa terbaik dengan akurasi sebesar 90,13%, presisi 96,25%, dan *F1-Score* 87,88%, dan waktu inferensi yaitu 127,76 milidetik mengungguli ResNet50V2 dan VGG16 baik dalam hal akurasi maupun efisiensi pelatihan. Hal ini memperkuat pemahaman bahwa model lightweight yang menggunakan bobot pretrained mampu memberikan generalisasi yang baik bahkan dengan jumlah epoch yang terbatas.

Penelitian ini mempertegas pentingnya pemanfaatan *transfer learning* dalam klasifikasi citra yang kompleks namun efisien. Model pretrained seperti MobileNetV2 memungkinkan pelatihan cepat, penggunaan sumber daya rendah, dan performa tinggi, yang sangat sesuai untuk deployment di perangkat edge seperti smartphone atau embedded system. Selain itu, kestabilan performa selama pelatihan dan generalisasi terhadap data baru menjadi nilai tambah signifikan.

Berdasarkan hasil penelitian dan evaluasi yang dilakukan, model MobileNetV2 sangat direkomendasikan untuk diimplementasikan dalam sistem klasifikasi sampah berbasis citra karena memberikan keseimbangan optimal antara akurasi, presisi, dan efisiensi komputasi. Untuk pengembangan lebih lanjut, penelitian dapat diarahkan pada klasifikasi multikategori yang lebih spesifik, seperti pemisahan sampah plastik, kertas, kaca, dan logam, yang akan meningkatkan

relevansi sistem terhadap kebutuhan pengelolaan sampah di dunia nyata. Penerapan teknik augmentasi data yang lebih komprehensif dan optimasi *hyperparameter* juga perlu dilakukan untuk lebih meningkatkan performa *recall*, terutama pada model yang cenderung konservatif seperti ResNet50V2. Hasil penelitian ini berpotensi untuk diintegrasikan ke dalam platform mobile (Android/iOS) sebagai aplikasi praktis yang memungkinkan pengguna melakukan pemilahan sampah secara real-time melalui kamera ponsel, mendukung kesadaran lingkungan dan praktik daur ulang yang lebih baik di tingkat individu. Selain itu, kombinasi model klasifikasi dengan perangkat *IoT* seperti kamera dan mikrokontroler pada tempat sampah pintar (*smart bin*) dapat meningkatkan otomatisasi dan efisiensi pengelolaan sampah di lingkungan publik dan domestik. Untuk skala yang lebih luas, integrasi sistem ke dalam layanan cloud akan memungkinkan pencatatan data klasifikasi secara otomatis, pelaporan statistik penggunaan, dan analitik lanjutan yang dapat mendukung pengembangan kebijakan manajemen sampah perkotaan berbasis data. Dengan pendekatan ini, sistem klasifikasi sampah berbasis citra tidak hanya menjadi solusi teknis yang akurat, tetapi juga pendorong transformasi digital dalam manajemen sampah perkotaan, lingkungan berbasis teknologi terkini, dan ekonomi sirkular.

REFERENCES

- [1] Kementerian Koordinator Bidang Pembangunan Manusia dan Kebudayaan Republik Indonesia, "Laporan Tahunan Pengelolaan Sampah Nasional." Accessed: Apr. 15, 2025. [Online]. Available: <https://www.kemenkopmk.go.id/72-juta-ton-sampah-di-indonesia-belum-terkelola-dengan-baik>
- [2] F. Dwiatmoko, D. Utami, N. A. Sivi, U. Nahdlatul, and U. Lampung, "Klasifikasi Citra Sampah Organik dan Non Organik Menggunakan Algoritma CNN (Convolutional Neural Network)."
- [3] R. N. J. S.Intam, A. Raihan, M. Alfajri, A. B. Kaswar, D. D. Andayani, and Asnidar, "Sistem Klasifikasi Jenis Sampah Berdasarkan Kombinasi Fitur Warnac Tekstur Menggunakan Artificial Neural Network Berbasis Pengolahan Citra Digital," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 2, pp. 411–420, Aug. 2024, doi: 10.25126/jtiik.20241128330.
- [4] D. Nurdiah, Y. K. Suprpto, and E. M. Yuniarno, "Gamelan Orchestra Transcription Using Neural Network," in *CENIM 2020 - Proceeding: International Conference on Computer Engineering, Network, and Intelligent Multimedia 2020*, Institute of Electrical and Electronics Engineers Inc., Nov. 2020, pp. 371–376. doi: 10.1109/CENIM51130.2020.9297988.
- [5] D. Nurdiah, E. M. Yuniarno, S. A. Wulandari, Y. K. Surapto, and M. H. Purnomo, "Deep Semantic Feature Extraction to Overcome Overlapping Frequencies for Instrument Recognition in Indonesian Traditional Music Orchestras," *IEEE Access*, vol. 12, pp. 76936–76954, 2024, doi: 10.1109/ACCESS.2024.3401699.
- [6] Y. Bengio, I. Goodfellow, and A. Courville, "Deep Learning," 2015.
- [7] R. C. . Gonzalez and R. E. . Woods, *Digital image processing*. Pearson, 2018.
- [8] A. Ibnul Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 1, Apr. 2022, doi: 10.28932/jutisi.v8i1.4314.
- [9] G. Aprisia Bahagia, M. Akbar Teknik Informatika, and M. buana Yogyakarta Gejayan Jembatan Merah Yogyakarta, "KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)," 2024.
- [10] 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 Management*, vol. 135, pp. 150–157, Nov. 2021, doi: 10.1016/j.wasman.2021.08.038.
- [11] R. Permana, H. Saldu, and D. I. Maulana, "OPTIMASI IMAGE CLASSIFICATION PADA JENIS SAMPAH DENGAN DATA AUGMENTATION DAN CONVOLUTIONAL NEURAL NETWORK," *Jurnal Sistem Informasi dan Informatika (Simika)*, vol. 5, 2022.
- [12] S. Yang, W. Xiao, M. Zhang, S. Guo, J. Zhao, and F. Shen, "Image Data Augmentation for Deep Learning: A Survey," Apr. 2022, [Online]. Available: <http://arxiv.org/abs/2204.08610>

- [13] L. Yong, L. Ma, D. Sun, and L. Du, "Application of MobileNetV2 to waste classification," *PLoS One*, vol. 18, no. 3 March, Mar. 2023, doi: 10.1371/journal.pone.0282336.
- [14] M. M. Islam, S. Hassan, M. Alamgir, S. M. T. Islam, J. A. Saju, and M. Nasim Akhtar, *TRANSFER LEARNING BASED SOLID WASTE CLASSIFICATION USING THE ORGANIC AND RECYCLABLE WASTE IMAGES*. [Online]. Available: <https://www.researchgate.net/publication/380167476>
- [15] D. Vieri, R. Susanto, E. S. Purwanto, and M. K. Ario, "Enhancing Waste Classification with YOLOv8 Models for Efficient and Accurate Sorting," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 889–895. doi: 10.1016/j.procs.2024.10.316.