

Klasifikasi Jenis Sampah Menggunakan *Transfer Learning* Berbasis *EfficientNetV2-B0* dengan Strategi *Fine-Tuning*

DOI: <http://dx.doi.org/10.35889/jutisi.v15i4.3773>

Creative Commons License 4.0 (CC BY – NC)

Jose Farrel Samgar^{1*}, Nur Rachmat²

Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

*e-mail Corresponding Author: josefarrelzx@gmail.com

Abstract

Manual waste sorting often leads to inefficient waste management and classification errors. This study implements the *EfficientNetV2-B0* architecture using transfer learning and a fine-tuning strategy to classify organic and recyclable waste images from the Waste Classification Data dataset, which contains two classes. The dataset was split into 80% training, 10% validation, and 10% testing data. The methodology included image preprocessing through resizing, float32 data type conversion, and the use of *EfficientNetV2-B0* internal preprocessing, followed by data augmentation, transfer learning, and fine-tuning of the last 30% of model layers using the Adam optimizer. Model performance was evaluated using accuracy, precision, recall, and F1-score metrics under two batch size settings, 16 and 32. The results showed that a batch size of 32 achieved the best performance, with 96.45% accuracy, 96.20% precision, 95.77% recall, and 95.99% F1-score. These findings demonstrate the effectiveness of *EfficientNetV2-B0* for waste image classification and its potential for automated waste sorting systems in various real-world environmental management applications.

Keywords: *Efficientnetv2-B0; Waste Classification; Transfer Learning; Fine-Tuning; Deep Learning*

Abstrak

Pemilahan sampah yang masih dilakukan secara manual sering menyebabkan proses pengelolaan sampah menjadi tidak efisien dan rentan terhadap kesalahan klasifikasi. Penelitian ini bertujuan mengimplementasikan arsitektur *EfficientNetV2-B0* berbasis *transfer learning* dengan strategi *fine-tuning* untuk mengklasifikasikan citra sampah organik dan *recyclable* menggunakan dataset Waste Classification Data yang terdiri atas dua kelas. Dataset dibagi menjadi 80% data pelatihan, 10% data validasi, dan 10% data pengujian. Tahapan penelitian dilakukan melalui *preprocessing* berupa *resizing*, konversi tipe data, dan pemanfaatan *preprocessing internal* *EfficientNetV2-B0*, augmentasi data, *transfer learning*, serta *fine-tuning* pada 30% lapisan terakhir model dengan menggunakan optimizer Adam. Evaluasi kinerja dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* dengan membandingkan dua skenario *batch size*, yaitu 16 dan 32. Hasil penelitian menunjukkan bahwa *batch size* 32 mampu menghasilkan performa terbaik dengan *accuracy* 96,45%, *precision* 96,20%, *recall* 95,77%, dan *F1-score* 95,99%. Hasil ini menunjukkan bahwa *EfficientNetV2-B0* dengan strategi *fine-tuning* efektif dalam mengklasifikasikan citra sampah serta berpotensi mendukung pengembangan sistem pemilahan sampah otomatis.

Kata kunci: *Efficientnetv2-B0; Klasifikasi Sampah; Transfer Learning; Fine-Tuning; Deep Learning*

1. Pendahuluan

Permasalahan sampah menjadi isu penting karena jumlah timbulan sampah terus meningkat seiring pertumbuhan penduduk dan aktivitas manusia [1]. Data dari Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) Kementerian Lingkungan Hidup dan Kehutanan (KLHK), pada tahun 2025 tercatat sebanyak 269 kabupaten/kota di seluruh Indonesia menghasilkan

timbulan sampah dengan total mencapai 27.864.914,87 ton per tahun, dimana sebesar 65,82% atau setara dengan 18.340.008,24 ton per tahun dari jumlah tersebut masih belum dapat terkelola dengan baik [2]. Kondisi tersebut menunjukkan bahwa pengelolaan sampah masih menghadapi tantangan, terutama berkaitan dengan rendahnya kesadaran pemilahan, keterbatasan fasilitas, dan perlunya solusi pengelolaan yang lebih efektif [3]. Pemilahan yang tepat diperlukan agar sampah organik dapat diarahkan untuk pengolahan kompos, sedangkan sampah *recyclable* dapat dimanfaatkan kembali melalui proses daur ulang. Dengan demikian, pengembangan sistem pemilahan sampah yang lebih efisien menjadi penting untuk mendukung pengelolaan sampah yang lebih berkelanjutan.

Pada praktiknya, proses pemilahan sampah masih banyak dilakukan secara manual. Cara tersebut memiliki beberapa kelemahan, seperti membutuhkan waktu yang cukup lama, memerlukan tenaga kerja, dan rentan terhadap kesalahan klasifikasi karena bergantung pada ketelitian manusia [4]. Kesalahan pemilahan dapat menyebabkan sampah yang masih dapat dimanfaatkan tercampur dengan sampah lain, sehingga menurunkan efektivitas proses pengolahan lanjutan. Beberapa pendekatan berbasis kecerdasan buatan telah dikembangkan untuk membantu proses pengenalan jenis sampah secara otomatis, baik melalui deteksi dan klasifikasi sampah berbasis *web* maupun klasifikasi citra menggunakan *machine learning* dan *deep learning* [5], [4]. Selain itu, penerapan *transfer learning* pada klasifikasi citra sampah juga menunjukkan bahwa model *pre-trained* dapat dimanfaatkan untuk mengenali pola visual sampah berdasarkan warna, tekstur, bentuk, dan karakteristik objek lainnya [6]. Oleh karena itu, diperlukan model klasifikasi citra yang mampu mengenali jenis sampah secara otomatis dengan performa yang baik.

Beberapa penelitian sebelumnya telah menerapkan *deep learning* dan *transfer learning* untuk menyelesaikan permasalahan klasifikasi sampah. Julu dan Nurdiyah [7] mengklasifikasikan sampah organik dan non-organik menggunakan VGG16, MobileNetV2, dan ResNet50V2, dengan hasil terbaik diperoleh MobileNetV2 sebesar 90,13% *accuracy*, 96,25% *precision*, dan 88,78% *F1-score*. Kumala dkk. [8] membandingkan MobileNetV2 dan VGG16 untuk klasifikasi sampah multi-kelas, dengan hasil MobileNetV2 memperoleh *accuracy* 95,6%, lebih tinggi dibandingkan VGG16 sebesar 89,13%. Ardana dan Kusri [9] membandingkan EfficientNet-B0 dan ResNet-50 pada *dataset* Waste Classification Data, dengan hasil EfficientNet-B0 memperoleh *accuracy* 97,25% dan lebih efisien secara komputasi dibandingkan ResNet-50. Penelitian lain oleh Wahid dkk. [10] menerapkan MobileNetV2 untuk klasifikasi sampah organik dan anorganik berbasis *Android* dengan *accuracy* sebesar 91%. Meskipun beberapa penelitian tersebut menunjukkan performa yang baik, penelitian Dhorojat dkk. [11] memperlihatkan bahwa EfficientNetV2 hanya mencapai *accuracy* 27% pada klasifikasi sampah, jauh lebih rendah dibandingkan MobileNetV2 yang mencapai 98%. Hasil tersebut menunjukkan adanya gap bahwa EfficientNetV2 masih perlu dioptimalkan melalui strategi pelatihan yang sesuai agar mampu menyesuaikan fitur visual terhadap karakteristik citra sampah.

Berdasarkan *gap* tersebut, penelitian ini mengusulkan penggunaan EfficientNetV2-B0 dengan pendekatan *transfer learning* dan strategi *fine-tuning* untuk klasifikasi citra sampah organik dan *recyclable*. EfficientNetV2-B0 dipilih karena merupakan pengembangan dari keluarga EfficientNet yang dirancang untuk meningkatkan efisiensi pelatihan dan penggunaan parameter, sehingga berpotensi diterapkan pada tugas klasifikasi citra. Untuk meningkatkan kemampuan generalisasi model, penelitian ini menerapkan *data augmentation* berupa *horizontal flip*, *random rotation*, *random zoom*, *random translation*, dan penyesuaian pencahayaan berbasis HSV. Penggunaan *data augmentation* didukung oleh penelitian Wahyudi dkk. [12] yang menunjukkan bahwa augmentasi dapat membantu meningkatkan performa model dan mengurangi risiko *overfitting*. Selain itu, *fine-tuning* dilakukan dengan membuka 30% *layer* terakhir agar model dapat menyesuaikan fitur terhadap *dataset* target, sejalan dengan penelitian Arief dkk. [13] yang menunjukkan bahwa *fine-tuning* dapat meningkatkan performa model *transfer learning*. Pelatihan model dilakukan menggunakan *optimizer Adam* karena *optimizer* ini mampu mendukung proses pembelajaran model secara stabil, sebagaimana ditunjukkan pada penelitian Wibowo [14] dan Djoas dkk. [15]. *Dataset* yang digunakan adalah Waste Classification Data dari Kaggle yang terdiri dari dua kelas, yaitu organik dan *recyclable* [16]. Kebaruan penelitian ini terletak pada penerapan EfficientNetV2-B0 untuk klasifikasi dua kelas sampah menggunakan kombinasi *transfer learning*, *data augmentation*, *fine-tuning* 30% *layer* terakhir, *optimizer Adam*, serta perbandingan dua skenario *batch size*, yaitu 16 dan 32. Melalui pendekatan tersebut,

penelitian ini diharapkan dapat menghasilkan model klasifikasi sampah yang akurat dan mendukung pengembangan sistem pemilahan sampah otomatis.

2. Metodologi

Penelitian ini merupakan penelitian berbasis *deep learning* yang bertujuan untuk membangun model klasifikasi citra sampah menggunakan EfficientNetV2-B0 dengan pendekatan *transfer learning* dan *fine-tuning*. Tahapan penelitian terdiri dari pengumpulan *dataset*, *preprocessing* dan augmentasi data, perancangan model, pelatihan model, serta pengujian dan evaluasi model.

2.1 Pengumpulan Dataset

Dataset yang digunakan pada penelitian ini adalah Waste Classification Data yang diambil dari Kaggle [16]. *Dataset* terdiri dari 25.077 citra sampah yang terbagi ke dalam 2 kelas yaitu, organik dengan total 13.966 citra gambar dan *recyclable* sebanyak 11.111 citra gambar.

Pembagian *dataset* dilakukan dengan rasio 80% untuk data *training*, 10% untuk data *validation*, dan 10% untuk data *testing*. Data *training* digunakan untuk melatih model dalam mengenali pola visual pada citra sampah. Data *validation* digunakan untuk memantau performa model selama proses pelatihan, sedangkan data *testing* digunakan untuk menguji kemampuan model terhadap data yang belum pernah digunakan pada proses pelatihan. Contoh gambar *dataset* dapat dilihat pada tabel 1.

Tabel 1. Dataset

Kategori	Jumlah	Contoh Gambar
Organik	13.966	
Recyclable	11.111	


2.2 Perancangan Model

Pada tahap ini dilakukan perancangan model yang diawali dengan proses *preprocessing* data setelah tahap pengumpulan *dataset*. Tahap *preprocessing* dilakukan dengan mengubah ukuran seluruh citra menjadi 224×224 piksel agar sesuai dengan ukuran input model EfficientNetV2-B0. Selanjutnya, citra dikonversi ke tipe *data* float32. Nilai piksel dipertahankan pada rentang 0–255 karena EfficientNetV2-B0 pada TensorFlow/Keras telah memiliki *preprocessing internal*, sehingga proses penyesuaian skala *input* dilakukan oleh *layer* bawaan model.

Data augmentation juga diterapkan untuk meningkatkan variasi citra dan mengurangi resiko *overfitting*. Teknik augmentasi yang digunakan meliputi horizontal flip, random rotation sebesar ± 18 derajat, random zoom sebesar $\pm 10\%$, random translation sebesar $\pm 10\%$ terhadap tinggi dan lebar citra, serta perubahan pencahayaan menggunakan pendekatan HSV dengan parameter hue $\pm 0,02$, saturation $\pm 0,2$, dan value atau brightness $\pm 0,2$.

Pada tahap selanjutnya dilakukan perancangan model menggunakan arsitektur EfficientNetV2-B0 yang telah dilatih sebelumnya menggunakan *dataset ImageNet* dengan metode *transfer learning*. Pada tahap awal, sebagian besar *layer* EfficientNetV2-B0 dibekukan agar fitur umum dari *ImageNet* tetap dipertahankan. Selanjutnya, dilakukan *fine-tuning* dengan membuka 30% *layer* terakhir agar model dapat menyesuaikan fitur visual terhadap karakteristik

citra sampah. Setelah proses tersebut, ditambahkan beberapa lapisan tambahan (*fully connected layer*) yang terdiri dari *Global Average Pooling*, *Dense layer* dengan fungsi aktivasi ReLU, serta *Dropout* untuk mengurangi *overfitting*. Pada bagian akhir digunakan *layer output* dengan fungsi aktivasi *Softmax* untuk melakukan klasifikasi dua kelas. Rancangan EfficientNetV2-B0 dapat dilihat pada gambar 1.



Gambar 1. Rancangan Arsitektur EfficientNetV2-B0

2.3 Pengujian dan Evaluasi

Pada tahapan ini, sistem yang telah dibuat sebelumnya akan melakukan uji coba terhadap data uji. Hasil prediksi yang diperoleh dari model kemudian dievaluasi menggunakan metode *confusion matrix*. Evaluasi ini bertujuan untuk mengukur kinerja model berdasarkan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Nilai dari masing-masing metrik tersebut dihitung menggunakan persamaan (1), (2), (3), dan (4).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \times 100\% \quad (4)$$

Selain menggunakan *confusion matrix*, penelitian ini juga melakukan pengujian *hyperparameter* pada variasi *batch size*. *Hyperparameter tuning* dilakukan untuk memperoleh kombinasi parameter yang paling sesuai agar model dapat menghasilkan performa yang optimal. Parameter yang digunakan dalam penelitian ini dapat dilihat pada tabel 2.


Tabel 2. Parameter yang Digunakan

Parameter	Nilai / Jumlah yang Digunakan
<i>Learning rate</i>	0.0001
<i>Batch Size</i>	16 dan 32
<i>Epoch</i>	50
<i>Optimizer</i>	Adam


3. Hasil dan Pembahasan

3.1. Hasil Pelatihan Model

Pelatihan model EfficientNetV2-B0 dilakukan dengan dua skenario *batch size* yaitu, *batch size* 16 dan 32. Setiap skenario dilatih melalui dua tahapan yaitu, *feature extraction* dan *fine-tuning*. Pada tahap *feature extraction* dilakukan selama 10 *epoch*, sedangkan pada tahap *fine-tuning* dilanjutkan setelah *epoch* ke-10 dengan membuka *layer* terakhir pada EfficientNetV2-B0 sebanyak 30%. Grafik *training history* untuk masing-masing skenario menunjukkan perkembangan *accuracy* dan *loss* selama proses pelatihan dapat dilihat pada gambar 2 dan gambar 3.



Gambar 2. Grafik Accuracy dan Loss Batch Size 16



Gambar 3. Grafik Accuracy dan Loss Batch Size 32

Pada kedua skenario, terlihat adanya perubahan nilai *accuracy* dan *loss* secara tiba-tiba pada *epoch* ke-10. Hal ini disebabkan oleh proses pelatihan berpindah dari tahap *feature extraction* ke tahap *fine-tuning*. Pada tahap *feature extraction*, sebagian besar layer EfficientNetV2-B0 dibekukan sehingga model hanya melatih layer klasifikasi tambahan. Setelah memasuki tahap *fine-tuning*, beberapa layer terakhir pada *backbone* dibuka kembali untuk dilatih ulang. Perubahan jumlah layer yang dapat dilatih menyebabkan bobot model kembali menyesuaikan diri terhadap karakteristik *dataset* sampah, sehingga *training accuracy* sempat menurun dan *training loss* sempat meningkat pada awal *fine-tuning*.


3.2. Hasil Evaluasi Model Batch Size 16

Pengujian model batch size 16 dilakukan menggunakan data *testing* sebanyak 2.508 citra. Hasil classification report menunjukkan bahwa model mampu mengklasifikasikan kedua kelas dengan performa yang baik. Kelas organik memperoleh *precision* 0,97, *recall* 0,97, dan *F1-score* 0,97, sedangkan kelas *recyclable* memperoleh *precision* 0,96, *recall* 0,96, dan *F1-score* 0,96.

Sebanyak 1.355 citra organik berhasil diklasifikasikan dengan benar sebagai organik, sedangkan 42 citra organik salah diklasifikasikan sebagai *recyclable*. Pada kelas *recyclable*, sebanyak 1.063 citra berhasil diklasifikasikan dengan benar sebagai *recyclable*, sedangkan 48 citra salah diklasifikasikan sebagai organik. Berdasarkan hasil pengujian, *model batch size* 16 memperoleh *accuracy* sebesar 96,41%, *precision* 0,9620, *recall* 0,9568, dan *F1-score* 0,9594. Hasil Evaluasi data *batch size* 16 dapat dilihat pada Tabel 3.

Tabel 3. Hasil Evaluasi Data Batch Size 16

Kategori	Precision	Recall	F1-Score	Accuracy
Organik	97%	97%	97%	96%
Recyclable	96%	96%	96%	



Gambar 4. Confusion Matrix Batch Size 16


3.3. Hasil Evaluasi Model Batch Size 32

Pengujian model *batch size* 32 juga dilakukan menggunakan data *testing* sebanyak 2.508 citra. Hasil *classification report* menunjukkan bahwa model *batch size* 32 memiliki performa klasifikasi yang baik pada kedua kelas. Kelas organik memperoleh *precision* 0,97, *recall* 0,97, dan *F1-score* 0,97, sedangkan kelas *recyclable* memperoleh *precision* 0,96, *recall* 0,96, dan *F1-score* 0,96.

Sebanyak 1.355 citra organik berhasil diklasifikasikan dengan benar sebagai organik, sedangkan 42 citra organik salah diklasifikasikan sebagai *recyclable*. Pada kelas *recyclable*, sebanyak 1.064 citra berhasil diklasifikasikan dengan benar sebagai *recyclable*, sedangkan 47 citra salah diklasifikasikan sebagai organik. Berdasarkan hasil pengujian, model *batch size* 32 memperoleh *accuracy* sebesar 96,45%, *precision* 0,9620, *recall* 0,9577, dan *F1-score* 0,9599. Hasil Evaluasi data *batch size* 32 dapat dilihat pada Tabel 4.

Tabel 4. Hasil Evaluasi Data Batch Size 32

Kategori	Precision	Recall	F1-Score	Accuracy
Organik	97%	97%	97%	96%
Recyclable	96%	96%	96%	



Gambar 5. Confusion Matrix Batch Size 32

3.4. Perbandingan Hasil *Batch Size* 16 dan 32

Perbandingan dilakukan untuk mengetahui pengaruh *batch size* terhadap performa model EfficientNetV2-B0 dalam klasifikasi citra sampah. Hasil perbandingan evaluasi model ditampilkan pada Tabel 5.

Tabel 5. Perbandingan Hasil Evaluasi *Batch Size* 16 dan 32


<i>Batch Size</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	TP	TN	FP	FN
16	96,41%	0,9620	0,9568	0,9594	1.063	1.355	42	48
32	96,45%	0,9620	0,9577	0,9599	1.064	1.355	42	47

Berdasarkan data tersebut, model dengan *batch size* 32 memperoleh *accuracy* sebesar 96,45%, lebih tinggi dibandingkan *batch size* 16 yang memperoleh *accuracy* sebesar 96,41%. Nilai *precision* pada kedua skenario sama, yaitu 0,9620. Namun, *batch size* 32 memperoleh *recall* sebesar 0,9577 dan *F1-score* sebesar 0,9599, lebih tinggi dibandingkan *batch size* 16 yang memperoleh *recall* 0,9568 dan *F1-score* 0,9594.

Pada *confusion matrix*, *batch size* 32 menghasilkan TP sebanyak 1.064 dan FN sebanyak 47, sedangkan *batch size* 16 menghasilkan TP sebanyak 1.063 dan FN sebanyak 48. Hal ini menunjukkan bahwa *batch size* 32 sedikit lebih baik dalam mengenali kelas recyclable. Dengan demikian, *batch size* 32 menjadi pilihan terbaik karena unggul pada *accuracy*, *recall*, *F1-score*, TP, dan FN, meskipun selisih performanya sangat kecil.

3.5. Analisis Karakteristik Citra yang Berhasil dan Tidak Berhasil Dikenali

Model EfficientNetV2-B0 yang dikembangkan telah menghasilkan performa klasifikasi yang tinggi, tetapi masih terdapat beberapa citra yang belum dikenali secara tepat. Kondisi ini dapat terjadi karena citra sampah memiliki variasi visual yang cukup besar, baik dari segi warna, bentuk, tekstur, pencahayaan, maupun latar belakang. Oleh karena itu, contoh citra yang berhasil dan tidak berhasil diklasifikasikan perlu dianalisis untuk melihat faktor visual yang memengaruhi hasil prediksi model. Contoh citra tersebut dapat dilihat pada Gambar 6.



Gambar 6. Contoh citra yang berhasil dan tidak berhasil diklasifikasikan oleh model

Pada Gambar 6, citra organik yang berhasil diklasifikasikan dengan benar memiliki objek utama yang terlihat jelas, yaitu wortel dengan warna dan bentuk yang mudah dikenali sebagai bahan organik. Model memberikan prediksi Organik dengan nilai *confidence* sebesar 1,00. Hal ini menunjukkan bahwa model mampu mengenali citra organik dengan baik ketika objek memiliki karakteristik visual yang kuat, seperti warna alami, bentuk jelas, dan latar belakang yang tidak terlalu mengganggu.

Pada citra *recyclable* yang berhasil diklasifikasikan dengan benar, model juga memberikan prediksi *Recyclable* dengan *confidence* sebesar 1,00. Citra tersebut memiliki pola visual yang cukup tegas dan berbeda dari citra organik, sehingga model dapat mengenali karakteristiknya dengan baik. Kondisi ini menunjukkan bahwa model mampu melakukan klasifikasi dengan tepat ketika fitur visual objek memiliki pola, warna, dan bentuk yang konsisten.

Sementara itu, pada contoh citra organik yang salah diklasifikasikan sebagai *recyclable*, model memberikan *confidence* sebesar 0,62. Nilai *confidence* yang lebih rendah dibandingkan citra yang benar diklasifikasikan menunjukkan bahwa model memiliki tingkat keyakinan yang tidak terlalu kuat pada prediksi tersebut. Kesalahan ini dapat terjadi karena objek pada citra memiliki warna dominan putih keabu-abuan, bentuk berulung, serta tekstur yang tidak menunjukkan ciri organik secara jelas. Karakteristik tersebut dapat menyebabkan model menganggap citra lebih mirip dengan kelas *recyclable*.

Pada contoh citra *recyclable* yang salah diklasifikasikan sebagai organik, model memberikan *confidence* sebesar 0,77. Kesalahan ini dapat disebabkan oleh warna objek yang menyerupai bahan makanan atau minuman, sehingga fitur visualnya menjadi lebih dekat dengan karakteristik kelas organik. Selain itu, objek pada citra memiliki tampilan yang kurang tegas sebagai sampah *recyclable*, sehingga model mengalami kesulitan dalam membedakan kelas yang sebenarnya.

Berdasarkan analisis tersebut, citra yang berhasil diklasifikasikan dengan benar umumnya memiliki objek utama yang jelas, warna yang sesuai dengan karakteristik kelas, dan latar belakang yang tidak terlalu kompleks. Sebaliknya, citra yang salah diklasifikasikan cenderung memiliki karakteristik visual yang ambigu, seperti warna yang menyerupai kelas lain, bentuk objek yang tidak khas, pencahayaan tertentu, atau pola visual yang membuat fitur antar kelas menjadi saling tumpang tindih. Hal ini menunjukkan bahwa kesalahan klasifikasi tidak hanya dipengaruhi oleh kemampuan model, tetapi juga oleh variasi visual pada *dataset* yang digunakan.

3.6. Pembahasan

Hasil penelitian menunjukkan bahwa model EfficientNetV2-B0 dengan pendekatan *transfer learning* dan *fine-tuning* mampu melakukan klasifikasi citra sampah organik dan *recyclable* dengan performa yang baik. Pada skenario *batch size* 32, model memperoleh *accuracy* sebesar 96,45%, *precision* 96,20%, *recall* 95,77%, dan *F1-score* 95,99%. Hasil tersebut menunjukkan bahwa tujuan penelitian untuk mengimplementasikan EfficientNetV2-B0 dalam klasifikasi citra sampah telah tercapai. Nilai *accuracy* yang tinggi menunjukkan bahwa sebagian besar data *testing* berhasil diklasifikasikan dengan benar, sedangkan nilai *precision*, *recall*, dan *F1-score* yang seimbang menunjukkan bahwa model memiliki kemampuan klasifikasi yang cukup stabil pada kedua kelas.

Berdasarkan hasil *confusion matrix*, model *batch size* 32 menghasilkan 2.419 prediksi benar dari total 2.508 data *testing*. Jumlah tersebut terdiri dari 1.355 citra organik yang berhasil diklasifikasikan sebagai organik dan 1.064 citra *recyclable* yang berhasil diklasifikasikan sebagai *recyclable*. Kesalahan klasifikasi berjumlah 89 citra, yaitu 42 citra organik salah diprediksi sebagai *recyclable* dan 47 citra *recyclable* salah diprediksi sebagai organik. Jumlah kesalahan yang relatif kecil menunjukkan bahwa model telah mampu mempelajari pola visual dari kedua kelas. Namun, kesalahan tersebut juga menunjukkan bahwa masih terdapat citra dengan karakteristik visual yang saling tumpang tindih, terutama pada citra yang memiliki warna, bentuk, tekstur, pencahayaan, atau latar belakang yang kurang khas.

Secara konsep, hasil penelitian ini mendukung kemampuan *Convolutional Neural Network* dalam mengenali pola visual citra secara otomatis. EfficientNetV2-B0 memanfaatkan bobot awal dari ImageNet melalui *transfer learning*, sehingga model tidak memulai proses pembelajaran dari bobot acak. Pendekatan ini membantu model mengenali fitur dasar citra, seperti tepi, warna, bentuk, tekstur, dan pola visual. Selanjutnya, *fine-tuning* dilakukan dengan membuka 30% *layer* terakhir agar model dapat menyesuaikan fitur yang lebih spesifik terhadap karakteristik citra sampah. Strategi ini sejalan dengan penelitian Arief dkk. [13] yang menunjukkan bahwa *fine-tuning* dapat meningkatkan performa model *transfer learning*.

Penerapan *data augmentation* juga menjadi salah satu faktor yang mendukung performa model. Augmentasi berupa *horizontal flip*, *random rotation*, *random zoom*, *random translation*, dan penyesuaian HSV membuat data *training* memiliki variasi yang lebih beragam. Variasi tersebut membantu model agar tidak hanya menghafal citra *training*, tetapi juga mampu

mengenali objek dalam kondisi yang berbeda. Hal ini penting karena citra sampah memiliki variasi visual yang tinggi, baik dari sisi posisi objek, sudut pengambilan gambar, pencahayaan, maupun latar belakang. Hasil ini mendukung penelitian Wahyudi dkk. [12] yang menunjukkan bahwa *data augmentation* dapat membantu meningkatkan performa model dan mengurangi risiko *overfitting*.

Perbandingan dua skenario *batch size* menunjukkan bahwa *batch size* 32 memberikan hasil yang sedikit lebih baik dibandingkan *batch size* 16. Model *batch size* 16 memperoleh *accuracy* 96,41%, *precision* 96,20%, *recall* 95,68%, dan *F1-score* 95,94%, sedangkan model *batch size* 32 memperoleh *accuracy* 96,45%, *precision* 96,20%, *recall* 95,77%, dan *F1-score* 95,99%. Selisih performa antara kedua skenario memang kecil, tetapi *batch size* 32 unggul pada *accuracy*, *recall*, *F1-score*, jumlah *true positive*, dan jumlah *false negative*. Hal ini menunjukkan bahwa *batch size* 32 memberikan proses pembelajaran yang sedikit lebih stabil, khususnya dalam mengenali kelas *recyclable*.

Jika dibandingkan dengan penelitian sebelumnya, hasil penelitian ini menunjukkan performa yang kompetitif. Penelitian Julu dan Nurdiah [7] menggunakan MobileNetV2 untuk klasifikasi sampah organik dan non-organik memperoleh *accuracy* sebesar 90,13%, sehingga hasil penelitian ini lebih tinggi sebesar 6,32%. Temuan ini juga memperkuat hasil penelitian Muslihati dkk. [17] yang mengonfirmasi bahwa klasifikasi biner berbasis konvolusi untuk kategori organik dan non-organik mampu menghasilkan kurva akurasi pengenalan yang stabil. Penelitian Kumala dkk. [8] yang menggunakan MobileNetV2 pada klasifikasi sampah multi-kelas memperoleh *accuracy* sebesar 95,6%, sehingga hasil penelitian ini lebih tinggi sebesar 0,85%. Selain itu, penelitian Wahid dkk. [10] memperoleh *accuracy* sebesar 91% pada klasifikasi sampah organik dan anorganik berbasis *Android*, sehingga model pada penelitian ini menunjukkan peningkatan *accuracy* sebesar 5,45%.

Hasil penelitian ini juga menunjukkan perbedaan yang signifikan dibandingkan penelitian Dharajat dkk. [11], yang melaporkan bahwa EfficientNetV2 hanya memperoleh *accuracy* sebesar 27% pada klasifikasi sampah. Pada penelitian ini, EfficientNetV2-B0 mampu memperoleh *accuracy* sebesar 96,45%. Perbedaan tersebut menunjukkan bahwa performa EfficientNetV2 sangat dipengaruhi oleh strategi pelatihan yang digunakan. Hasil akurasi yang tinggi ini sejalan dengan temuan Salsabila dan Muljono [18] yang menunjukkan bahwa EfficientNetB0 dengan pendekatan *transfer learning* dan *fine-tuning* mampu mengungguli model-model CNN klasik lainnya. Penggunaan *preprocessing* yang sesuai, *data augmentation*, *transfer learning*, *fine-tuning*, optimizer Adam, serta pengujian *batch size* dapat membantu model menyesuaikan pola visual pada *dataset* target dengan lebih baik.

Kontribusi penelitian ini terletak pada penerapan EfficientNetV2-B0 untuk klasifikasi citra sampah organik dan *recyclable* dengan kombinasi *transfer learning*, *data augmentation*, *fine-tuning*, optimizer Adam, dan perbandingan *batch size*. Hasil penelitian ini menunjukkan bahwa EfficientNetV2-B0 masih memiliki potensi untuk digunakan pada domain klasifikasi sampah apabila strategi pelatihannya dirancang dengan tepat. Dalam konteks pengembangan ilmu pengetahuan, penelitian ini memperkuat bukti bahwa arsitektur *deep learning modern* dapat diterapkan pada bidang pengelolaan lingkungan, khususnya untuk mendukung sistem pemilahan sampah otomatis berbasis citra. Penerapan *transfer learning* ini juga mendukung landasan bagi pengembangan sistem deteksi objek otomatis guna memetakan koordinat dan letak sampah secara *real-time* [19].

Meskipun menghasilkan performa yang baik, penelitian ini masih memiliki beberapa keterbatasan. Pertama, klasifikasi hanya dilakukan pada julidua kelas, yaitu organik dan *recyclable*, sehingga model belum dapat membedakan jenis sampah secara lebih rinci seperti plastik, kertas, kaca, logam, dan sisa makanan. Kedua, *dataset* yang digunakan berasal dari sumber publik, sehingga kondisi citra belum tentu sepenuhnya mewakili kondisi nyata di lapangan. Ketiga, model belum diimplementasikan secara langsung pada sistem *real-time* berbasis kamera, *web*, *mobile*, atau perangkat *embedded*. Oleh karena itu, penelitian selanjutnya dapat memperluas jumlah kelas, menggunakan *dataset* dengan kondisi pengambilan gambar yang lebih bervariasi, serta mengimplementasikan model ke dalam sistem pemilahan sampah otomatis.

4. Simpulan

Penelitian ini berhasil mengembangkan model klasifikasi citra sampah menggunakan arsitektur EfficientNetV2-B0 dengan strategi *transfer learning* dan *fine-tuning*. *Dataset* yang digunakan adalah *Waste Classification Data* dari Kaggle yang terdiri dari dua kelas, yaitu organik

dan *recyclable*, dengan total 25.077 citra. Proses pelatihan dilakukan menggunakan *optimizer Adam* dan dua skenario *batch size*, yaitu 16 dan 32. Berdasarkan hasil pengujian, model dengan *batch size* 16 memperoleh *accuracy* sebesar 96,41%, *precision* 0,9620, *recall* 0,9568, dan *F1-score* 0,9594. Sementara itu, model dengan *batch size* 32 memperoleh *accuracy* sebesar 96,45%, *precision* 0,9620, *recall* 0,9577, dan *F1-score* 0,9599. Hasil tersebut menunjukkan bahwa *batch size* 32 menjadi skenario terbaik karena menghasilkan *accuracy*, *recall*, dan *F1-score* yang lebih tinggi dibandingkan *batch size* 16, meskipun selisih performanya sangat kecil. Dengan demikian, EfficientNetV2-B0 dengan *fine-tuning* dapat digunakan secara efektif untuk mengklasifikasikan citra sampah organik dan *recyclable*. Untuk pengembangan selanjutnya, penelitian dapat dilakukan dengan menambah jumlah kelas sampah, menggunakan *dataset* dengan kondisi citra yang lebih bervariasi, serta mengimplementasikan model ke dalam sistem pemilahan sampah otomatis berbasis *web* atau *mobile*.

Daftar Referensi

- [1] S. U. Purba, S. Faradiba, and J. W. Sitanggang, "Tren dan distribusi timbulan sampah serta sumbernya pada kabupaten dan kota di Indonesia," *Heal. Care J. Kesehat.*, vol. 14, no. 2, pp. 256–264, 2025, <https://doi.org/10.36763/57dzbk98>
- [2] Kementerian Lingkungan Hidup dan Kehutanan, "Sistem Informasi Pengelolaan Sampah Nasional (SIPSN)." Kementerian Lingkungan Hidup dan Kehutanan, 2025, [Online]. Available: <https://sampahnasional.kemenvh.go.id> [Diakses: 12 April 2026].
- [3] L. J. Lingga, M. Yuana, N. A. Sari, H. N. Syahida, and C. S. Shahron, "Sampah di Indonesia : Tantangan dan Solusi Menuju Perubahan Positif," *Innov. J. Soc. Sci. Res. Vol.*, vol. 4, no. 4, pp. 12235–12247, 2024, <https://doi.org/10.31004/innovative.v4i4.14542>
- [4] A. M. Akbar, M. Basri, and Wahyuddin, "Implementasi Machine Learning Menggunakan Algoritma Klasifikasi untuk Mendeteksi Jenis Sampah," *J. Publ. Manaj. Inform.*, vol. 3, no. 3, pp. 152–161, 2025, <https://doi.org/10.55606/jupumi.v3i3.3751>
- [5] M. S. Nabila, H. Herlawati, and A. Hidayat, "Pendeteksian dan Klasifikasi Sampah pada Bank Sampah Berbasis Web Menggunakan YOLO v11," *J. Students' Res. Comput. Sci.*, vol. 6, no. 1, pp. 99–112, 2025, <https://doi.org/10.31599/r5me0z35>
- [6] W. F. Akbar, N. C. Wibowo, and D. S. Y. Kartika, "Implementasi Transfer Learning Model DenseNet169 Untuk Klasifikasi Citra Jenis Sampah," *J. Tek. Inform. dan Sist. Inf.*, vol. 11, no. 4, pp. 495–506, 2025, <https://doi.org/10.35957/jatisi.v11i4.8352>
- [7] D. I. S. H. Julu and D. Nurdiah, "KLASIFIKASI SAMPAH ORGANIK DAN MENGGUNAKAN TRANSFER LEARNING NON," vol. 23, no. 1, pp. 12–29, 2025, <https://doi.org/10.26623/transformatika.v23i1.12201>
- [8] R. A. Kumala, C. A. Sari, and E. H. Rachmawanto, "A Comparison of MobileNetV2 and VGG16 Architectures with Transfer Learning for Multi-Class Image-Based Waste Classification," *J. Appl. Informatics Comput.*, vol. 9, no. 4, pp. 1610–1624, 2025, <https://doi.org/10.30871/jaic.v9i4.9958>
- [9] W. M. Ardana and Kusri, "Optimasi Algoritma Convolutional Neural Network dengan Arsitektur Efficientnet-B0 dan Resnet-50 untuk Klasifikasi Jenis Sampah," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 4, pp. 1274–1286, 2025, <https://doi.org/10.57152/malcom.v5i4.2030>
- [10] A. T. N. Wahid, F. G. Affifudin, M. Aditya, and D. Muriyatmoko, "Implementasi Arsitektur MobileNetV2 untuk Klasifikasi Sampah Organik dan Anorganik Berbasis Android," *Pros. Semin. Nas. Teknol. DAN SAINS*, vol. 5, no. 1, pp. 907–913, 2026, <https://doi.org/10.29407/hby4zx45>
- [11] N. F. S. Dharajat, M. Y. C. Furqonsyah, F. M. Ghifary, D. F. Ardiyanto, and M. F. Hidayattullah, "Perbandingan Akurasi dan Performa MobileNetV2 dan EfficientNetV2 Untuk Klasifikasi Sampah," vol. 14, no. 01, pp. 16–22, 2026, doi: 10.26418/justin.v14i1.89086.
- [12] I. P. A. T. Wahyudi, I. G. I. Sudipa, L. G. B. Libraeni, and M. L. Radhitya, "Performance Comparison of MobileNet and EfficientNet Architectures in Automatic Classification of Bacterial Colonies," vol. 6, no. 2, pp. 333–342, 2025, <https://doi.org/10.56705/ijodas.v6i2.218>
- [13] N. S. Arief, W. A. Putra, and D. S. R. Pratama, "Implementasi Cnn Arsitektur Mobilenetv2 Untuk Klasifikasi Tulisan Aksara Jawa," *Pros. Semin. Nas. Teknol. DAN SAINS*, vol. 3, no. 1, pp. 298–303, 2024, <https://doi.org/10.29407/z1cbjw36>
- [14] H. T. Wibowo, "Klasifikasi Rontgen Citra Paru untuk COVID-19 Menggunakan Convolutional

- Neural Network Berbasis Arsitektur EfficientNetV2,” *Decod. J. Pendidik. Teknol. Inf.*, vol. 4, no. 1, pp. 278–289, 2024, <https://doi.org/10.51454/decode.v4i1.349>
- [15] D. O. Djoas, A. I. Firdaus, H. A. Ningsih, I. Anggraeny, and R. D. Saputra, “Klasifikasi Jenis Bunga Menggunakan Algoritma Convolutional Neural Network (CNN),” *J. Elektron. dan Komput.*, vol. 18, no. 2, pp. 394–404, 2026, <https://doi.org/10.51903/elkom.v18i2.3238>
- [16] S. Sekar, “Waste Classification Data,” Kaggle, 2019, [Online]. Available: <https://www.kaggle.com/datasets/techsash/waste-classification-data> [Diakses: 12 April 2026].
- [17] Muslihati, S. Sahibu, and I. Taufik, “Implementation of the Convolutional Neural Network Algorithm for Classifying Types of Organic and Non-Organic Waste,” vol. 4, no. July, pp. 840–852, 2024, <https://doi.org/10.57152/malcom.v4i3.1346>
- [18] A. A. Salsabila and Muljono, “Penerapan Arsitektur Deep Learning EfficientNetB0 Berbasis Citra Digital untuk Meningkatkan Kinerja Sistem Klasifikasi Sampah Organik, Anorganik, dan B3,” vol. 12, no. 6, pp. 1006–1017, 2025, doi: 10.30865/jurikom.v12i6.9360.
- [19] A. A. Fathurrahman and F. Akbar, “Perancangan Sistem Identifikasi Jenis Sampah Menggunakan Tensorflow Object Detection Dan Transfer Learning,” vol. 10, no. 1, pp. 64–71, 2024, <https://doi.org/10.25077/TEKNOSI.v10i1.2024.64-71>