

OPTIMASI MODEL RESNET50 UNTUK KLASIFIKASI SAMPAH

Ahmad Sihabillah¹⁾, Abu Tholib^{2,*}, Illiyah Ibnul Basit³⁾

^{1, 2, 3)}Teknik Informatika, Fakultas Teknik Universitas Nurul Jadid

Karanganyar, Paiton, Probolinggo, 67291

e-mail: asihab58@gmail.com¹⁾, abu@unuja.ac.id²⁾, illiyahibnulbasit@gmail.com³⁾

*corresponding author

(Naskah masuk : 18 Januari 2025 Diterima untuk diterbitkan : 21 April 2025)

ABSTRAK

Penelitian ini mengkaji pemanfaatan arsitektur ResNet50 dalam klasifikasi sampah organik dan anorganik untuk meningkatkan efisiensi pemilahan sampah secara otomatis. Dataset yang digunakan terdiri dari 12.565 gambar sampah organik dan 9.999 gambar sampah anorganik, mencakup berbagai variasi kondisi lingkungan, seperti pencahayaan, ukuran, dan bentuk. Tahapan penelitian meliputi preprocessing data, yang mencakup augmentasi gambar untuk menambah variasi, pembagian dataset menjadi data pelatihan dan validasi, serta penyesuaian bobot kelas untuk menangani ketidakseimbangan dataset. Model dilatih selama lima epoch dengan akurasi validasi tertinggi sebesar 80,15% pada epoch terakhir. Hasil evaluasi menggunakan metrik precision, recall, dan f1-score menunjukkan performa yang baik, dengan kategori sampah organik mencapai recall 91% dan f1-score 84%. Namun, kategori sampah anorganik memiliki precision sebesar 85% dengan recall yang lebih rendah, yaitu 67%. Analisis Confusion matrix mengungkapkan bahwa model mampu mengklasifikasikan sebagian besar sampel dengan benar, meskipun masih terdapat beberapa kesalahan pada kategori anorganik. Secara keseluruhan, penelitian ini membuktikan efektivitas ResNet50 dalam meningkatkan akurasi klasifikasi sampah, mendukung pengelolaan sampah yang berkelanjutan. Dengan optimisasi lebih lanjut, seperti penyesuaian hyperparameter atau augmentasi tambahan, model ini memiliki potensi untuk mencapai performa yang lebih tinggi dalam aplikasi praktis.

Kata Kunci: ResNet50, klasifikasi sampah, organik, anorganik

ABSTRACT

This study examines the utilization of the ResNet50 architecture in classifying organic and inorganic waste to enhance the efficiency of automated waste sorting. The dataset used consists of 12,565 images of organic waste and 9,999 images of inorganic waste, covering various environmental conditions such as lighting, size, and shape. The research stages include data preprocessing, encompassing image augmentation to increase variation, splitting the dataset into training and validation sets, and adjusting class weights to handle dataset imbalance. The model was trained for five epochs, achieving the highest validation accuracy of 80.15% in the final epoch. Evaluation results using precision, recall, and f1-score metrics indicate good performance, with the organic waste category achieving a recall of 91% and an f1-score of 84%. However, the inorganic waste category obtained a precision of 85%, with a lower recall of 67%. Analysis of the Confusion matrix reveals that the model accurately classified most samples, although some errors were observed in the inorganic category. Overall, this study demonstrates the effectiveness of ResNet50 in improving waste classification accuracy, supporting sustainable waste management. With further optimization, such as hyperparameter adjustments or additional augmentation, this model has the potential to achieve even higher performance in practical applications.

Keywords: ResNet50, waste classification, organic, inorganic

I. PENDAHULUAN

Permasalahan pengelolaan sampah semakin kompleks di tengah meningkatnya populasi global dan urbanisasi yang pesat, terutama dalam upaya menuju keberlanjutan lingkungan[1]. Salah satu tantangan utama dalam pengelolaan sampah adalah proses pemilahan, yang merupakan langkah awal dan krusial dalam upaya mengurangi volume sampah yang berakhir di tempat pembuangan akhir serta mendukung proses daur ulang[2]. Namun, peningkatan urbanisasi juga menyebabkan meningkatnya tekanan terhadap sistem pengelolaan sampah konvensional, yang sering kali tidak mampu mengikuti

lonjakan volume dan kompleksitas sampah yang dihasilkan[3]. Sayangnya, metode pemilahan sampah konvensional yang umumnya mengandalkan tenaga manusia seringkali tidak efisien, rawan kesalahan, dan mahal, terutama jika diterapkan dalam skala besar[4].


Seiring dengan kemajuan dalam teknologi kecerdasan buatan (AI), khususnya dalam bidang pembelajaran mendalam (*deep learning*), muncul potensi besar untuk otomatisasi pemilahan sampah menggunakan algoritma berbasis *computer vision* yang dapat meningkatkan akurasi serta efisiensi proses[5]. Pendekatan berbasis *deep learning*, khususnya dengan *Convolutional Neural Network* (CNN), telah banyak digunakan dalam berbagai tugas klasifikasi gambar[6]. Namun, penelitian sebelumnya yang menggunakan algoritma CNN untuk pemilahan sampah menghadapi beberapa keterbatasan, terutama dengan keterbatasan dalam jumlah datasetnya[7]. Masalah *vanishing gradient* yang muncul pada lapisan jaringan dalam juga menjadi permasalahan utama dalam penerapan algoritma CNN[8]. Untuk mengatasi masalah *vanishing gradient* ini, arsitektur *ResNet* dengan koneksi lompatnya (*skip connection*) memungkinkan aliran gradien balik secara lebih efektif, sehingga model dapat dilatih lebih dalam tanpa mengalami degradasi kinerja[9]. Selain itu, struktur jaringan *ResNet* yang lebih dalam dan stabil membuatnya lebih tahan terhadap variasi kondisi lingkungan, seperti pencahayaan, cuaca, dan kelembapan, yang sering kali memengaruhi kualitas citra sampah dalam penerapan lapangan[10].

Penelitian ini bertujuan untuk mengembangkan sistem pemilahan sampah otomatis berbasis arsitektur *ResNet*, yang telah terbukti efektif dalam mengatasi masalah *vanishing gradient* dan mengoptimalkan kinerja pada jaringan dalam serta handal dalam melatih dataset yang beragam dan berjumlah besar[11]. Dengan pendekatan ini, *ResNet* diharapkan mampu mengekstrak fitur-fitur penting dari gambar sampah pada tingkat detail yang lebih tinggi, sehingga dapat lebih akurat dalam mengklasifikasikan sampah ke dalam kategori organik dan anorganik. Selain itu, penelitian ini juga akan mengeksplorasi pengaruh berbagai hyperparameter terhadap kinerja model, dengan tujuan menemukan konfigurasi model yang optimal dan lebih adaptif terhadap variasi sampah.

Untuk mencapai tujuan tersebut, penelitian ini akan dilakukan dalam beberapa tahap. Pertama, kami akan melakukan pengumpulan dan pra-pemrosesan data citra sampah dari berbagai kondisi pencahayaan, ukuran, dan bentuk untuk melatih model *ResNet*. Kedua, model akan dilatih dan diuji menggunakan dataset yang telah dibersihkan, dan berbagai kombinasi *hyperparameter* akan dieksplorasi untuk mengetahui pengaruhnya terhadap kinerja klasifikasi.

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam pengembangan teknologi pemilahan sampah otomatis yang lebih canggih dan mendukung upaya pengelolaan sampah yang berkelanjutan. Kami juga akan mengevaluasi performa model terhadap beberapa tantangan yang ada, seperti kesulitan dalam mengklasifikasikan sampah yang memiliki kemiripan visual tinggi atau sampah yang terkontaminasi dengan bahan lain. Selain itu, analisis terhadap kemampuan generalisasi model juga akan dilakukan untuk mengetahui sejauh mana model dapat diaplikasikan pada jenis sampah dan kondisi lingkungan yang berbeda.

II. METODE PENELITIAN



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Penelitian ini menggunakan dataset sampah organik dan anorganik dari *Kaggle* untuk melatih model. Dataset berjumlah 22.564 gambar yang mencakup dua kategori utama, yaitu sampah organik dengan total data sebanyak 12.565 gambar dan anorganik dengan total data sebanyak 9.999 gambar, yang dikumpulkan dari berbagai kondisi lingkungan. Dataset ini dipilih untuk mencerminkan variasi realistis, termasuk perbedaan dalam pencahayaan, ukuran, bentuk, serta kontaminasi bahan lain. Sampah organik meliputi sisa makanan dan material *biodegradable* lainnya, sedangkan sampah anorganik meliputi plastik, logam, kertas, dan bahan lainnya yang tidak terurai secara alami.

2.2 Preprocessing Data

Untuk memastikan kualitas data dan meningkatkan kinerja model, dilakukan beberapa tahap preprocessing. Adapun tahapan *preprocessing* pada penelitian ini meliputi persiapan dataset, pembagian data untuk pelatihan dan pengujian, augmentasi data untuk pelatihan, penyesuaian ukuran gambar, normalisasi piksel, dan pengisian piksel kosong.

2.3 Pemilihan Model

Model yang digunakan dalam penelitian ini adalah *ResNet50*. *ResNet50* adalah model *ResNet* yang lebih dalam dengan 50 lapisan. Keunikan dari *ResNet* adalah penggunaan *skip connection* yang memungkinkan gradien untuk mengalir lebih baik selama pelatihan yang mana dalam hal ini dapat mengurangi masalah *vanishing gradient* yang sering terjadi pada model yang lebih dalam[12]. Model ini terdiri dari residual blocks yang memungkinkan input untuk melewati satu atau lebih lapisan. Untuk membantu dalam mempertahankan informasi penting dan mempercepat konvergensi selama pelatihan.

2.4 Evaluasi Model

Untuk menilai kinerja model dalam mendeteksi sampah organik dan anorganik, beberapa metrik evaluasi yang digunakan pada penelitian ini adalah :

1) Akurasi

Akurasi adalah metrik dasar yang digunakan untuk mengukur seberapa sering model memprediksi kelas yang benar[13]. Metrik ini memberikan gambaran umum dari performa model, meskipun dapat kurang informatif ketika terjadi ketidakseimbangan antar kelas, di mana kelas minoritas dapat diabaikan. Rumus dalam menentukan akurasi dari model *ResNet50* ditunjukkan oleh **persamaan 1** berikut :

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

Keterangan :

TP (True Positive) = prediksi yang benar sebagai kelas positif

TN (True Negative) = prediksi yang benar sebagai kelas negatif

FP (False Positive) = prediksi yang salah sebagai kelas positif

FN (False Negative) = prediksi yang salah sebagai kelas negatif

2) Precision dan Recall

Precision dan *recall* sangat penting, terutama ketika terdapat ketidakseimbangan antara jumlah sampah organik dan anorganik. *Precision* mengukur seberapa akurat model dalam memprediksi sampah organik atau anorganik yang benar dari seluruh prediksi yang dilakukan. Sementara *Recall* mengukur kemampuan model dalam menemukan semua sampah organik atau anorganik yang sebenarnya. Kedua metrik ini sangat krusial untuk memastikan bahwa model tidak mengabaikan kelas minoritas dan dapat mendeteksi setiap jenis sampah dengan tepat. *Precision* dihitung menggunakan rumus pada persamaan 2 sedangkan rumus *recall* ditunjukkan oleh persamaan 3

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

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

3) *F1-Score*

F1-Score memberikan gambaran yang lebih seimbang mengenai kinerja model, dengan menggabungkan *precision* dan *recall* dalam satu nilai tunggal. Ini sangat berguna apabila kedua metrik tersebut, *precision* dan *recall*, sama-sama penting untuk diperhatikan, terutama pada kasus dengan ketidakseimbangan kelas. Rumus *F1-Score* ditunjukkan oleh persamaan 3 berikut :

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

4) *Confusion Matrix*

Confusion matrix digunakan untuk memvisualisasikan kesalahan klasifikasi secara lebih spesifik. Dengan matriks ini, kita dapat melihat dengan jelas berapa banyak sampah yang terklasifikasi dengan benar pada setiap kelas true positive (TP), serta berapa banyak kesalahan yang terjadi, seperti false positives (FP) dan false negatives (FN). Ini memungkinkan analisis lebih lanjut mengenai jenis kesalahan yang dibuat oleh model dan memberikan wawasan untuk perbaikan model.

III. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Dataset

Dataset diperoleh melalui situs *Kaggle.com*, yang dapat diakses melalui URL <https://www.kaggle.com/eldadvikorian/dataset-sampah-organik-dan-anorganik>. Dataset . Berikut adalah contoh gambar mentah dari dataset tersebut dan belum melalui proses pengolahan :



Gambar 2. Sampel Gambar Dari Dataset

3.2 Preprocessing Data

1) Persiapan Dataset

Dataset yang sudah diimport kemudian dilakukan pengolahan data yang bertujuan untuk mengorganisasi dan mempersiapkan dataset agar siap digunakan dalam pelatihan model. Pada proses ini, gambar-gambar sampah dari berbagai kategori seperti plastik, logam, dan kertas diakses dari struktur folder, kemudian dipasangkan dengan label masing-masing. Seluruh data dikonversi ke dalam format DataFrame yang berisi path file gambar dan label kategorinya, sehingga mempermudah proses selanjutnya yakni preprocessing data. Tahap ini dilakukan untuk memastikan data tersusun rapi dan konsisten, sehingga meningkatkan efisiensi dan performa model klasifikasi.

	filepath	label
0	/content/dataset-sampah-organik-dan-anorganik/...	Anorganik
1	/content/dataset-sampah-organik-dan-anorganik/...	Anorganik
2	/content/dataset-sampah-organik-dan-anorganik/...	Anorganik
3	/content/dataset-sampah-organik-dan-anorganik/...	Anorganik
4	/content/dataset-sampah-organik-dan-anorganik/...	Anorganik

Gambar 3. Detail Isi Dataframe

Pembagian Dataset

Dataset yang telah diformat dalam bentuk DataFrame dibagi menjadi dua bagian utama, yaitu data latih, yang digunakan untuk melatih model, dan data uji, yang digunakan untuk mengevaluasi performa model selama proses pelatihan. Pembagian data dilakukan dengan proporsi 80% untuk data latih (sebanyak 18.051 data) dan 20% untuk data uji (sebanyak 4.513 data). Proses pembagian dilakukan dengan memastikan bahwa proporsi setiap kategori data pada kolom label tetap seimbang di kedua bagian tersebut. Pendekatan ini disebut stratifikasi, yang bertujuan untuk menjaga representasi data dari setiap kategori, sehingga hasil pelatihan dan evaluasi lebih akurat dan tidak bias terhadap kategori tertentu[14].

2) Augmentasi Data Untuk Pelatihan

Augmentasi data dilakukan untuk menambah variasi dalam dataset tanpa perlu menambah jumlah data secara langsung. Teknik-teknik yang digunakan dalam penelitian ini meliputi rotasi gambar (*rotation range*) yaitu memutar gambar secara acak hingga 45 derajat ke kanan atau kiri untuk membuat model lebih tahan terhadap rotasi objek, pembalikan gambar (*horizontal dan vertical flip*) yang dilakukan dengan membalik gambar secara *horizontal* dan *vertikal* secara acak, efektif untuk data yang simetris atau tidak memiliki orientasi tetap, penyesuaian kecerahan (*brightness range*) di mana kecerahan gambar diubah secara acak antara 90% hingga 110% untuk membantu model beradaptasi dengan pencahayaan yang bervariasi, pergeseran gambar (*width dan height shift range*) dengan gambar digeser secara horizontal dan vertikal hingga 15% untuk mensimulasikan variasi posisi objek, perbesaran dan pengecilan gambar (*zoom range*) yaitu melakukan *zoom in* atau *zoom out* pada gambar hingga 15% agar model dapat mengenali objek dari berbagai jarak, pergeseran sudut (*shear*) yang menerapkan transformasi geser hingga 5% untuk membuat model lebih tahan terhadap distorsi perspektif, normalisasi piksel (*rescale*) yang mengubah skala nilai piksel gambar dari 0-255 menjadi 0-1 untuk mempercepat pelatihan dengan data yang lebih terstandarisasi, serta pengisian piksel kosong (*fill mode*) yaitu mengisi piksel kosong akibat transformasi dengan warna piksel terdekat untuk menjaga konsistensi gambar.

3) Penyesuaian Ukuran Gambar

Setelah proses augmentasi, gambar kemudian diubah ukurannya menjadi 384×384 piksel agar semua gambar memiliki dimensi yang konsisten sebelum diproses lebih lanjut oleh model.

4) Penyesuaian Bobot Kelas

Penyesuaian bobot kelas (*Class Weight Adjustment*) merupakan salah satu teknik penting dalam penanganan dataset yang tidak seimbang (*imbalanced dataset*), terutama dalam tugas klasifikasi[15]. Ketidakseimbangan kelas terjadi ketika jumlah data pada satu atau beberapa kelas jauh lebih banyak dibandingkan kelas lainnya, yang dapat menyebabkan model bias terhadap kelas mayoritas dan mengabaikan kelas minoritas. Dalam penelitian ini, penyesuaian bobot kelas dilakukan dengan formula berikut :

$$\text{Bobot (kelas)} = \frac{\text{Total jumlah sampel}}{\text{Jumlah kelas} \times \text{Jumlah kelas tersebut}} \quad (5)$$

Berdasarkan formula tersebut, perhitungan bobot untuk masing-masing kelas pada dataset yang terdiri dari dua kelas, yaitu Organik dan Anorganik, adalah sebagai berikut :


$$\text{Bobot (Organik)} = \frac{22.564}{2 \times 12.565} = 0.89788102 \quad (6)$$

$$\text{Bobot (Anrganik)} = \frac{22.564}{2 \times 9.999} = 1.12832854 \quad (7)$$

Hasil perhitungan di atas menunjukkan bahwa bobot untuk kelas Organik adalah 0.89788102, sedangkan bobot untuk kelas Anorganik adalah 1.12832854. Bobot ini dihitung berdasarkan

pendekatan berbasis distribusi data, di mana kelas dengan jumlah sampel lebih sedikit diberi bobot yang lebih besar. Penyesuaian bobot ini diterapkan selama proses pelatihan model dengan tujuan untuk mengurangi bias terhadap kelas mayoritas. Dengan demikian, model dapat belajar lebih baik pada kelas minoritas, yang pada akhirnya diharapkan dapat meningkatkan performa klasifikasi secara keseluruhan.

3.3 Pembuatan Model



Gambar 4. 10 Lapisan Awal ResNet50

Gambar 4 di atas adalah ilustrasi dari sepuluh lapisan pertama pada model ResNet50. Model ini dibangun menggunakan blok residual sebagai komponen utama, di mana *Shortcut connections* digunakan untuk menghindari masalah *vanishing gradient*. Setiap blok residual terdiri dari beberapa

lapisan *convolutional* (1×1 dan 3×3), *batch normalization*, dan fungsi aktivasi *ReLU*. Input model berupa tensor dengan dimensi 384×384 dan 3 saluran warna (RGB) yang kemudian melewati blok awal berupa *convolutional layer* besar berukuran 7×7 dengan *stride* 2×2 , *batch normalization*, *ReLU*, dan pooling berukuran 3×3 . Selanjutnya, model terdiri dari lima tahap blok, dengan jumlah filter yang meningkat di setiap blok untuk menangkap fitur yang semakin kompleks. *Shortcut connections* di setiap blok residual menambahkan input langsung ke output untuk menjaga informasi penting selama propagasi. Setelah semua blok residual, model menggunakan *global average pooling* untuk mengurangi dimensi data tanpa kehilangan fitur penting, diikuti dengan lapisan *fully connected* yang menggunakan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas.

3.4 Pelatihan Model

Model ini dikompilasi dengan optimasi Adam, fungsi *loss categorical crossentropy*, dan metrik akurasi. Proses pelatihan dilakukan dalam 32 *batch* selama lima *epoch* menggunakan data pelatihan dan validasi, dengan penerapan penyesuaian bobot kelas untuk menangani ketidakseimbangan dataset. Hasil analisis menunjukkan adanya peningkatan akurasi pada data pelatihan dari *epoch* pertama hingga kelima, yang disertai dengan fluktuasi performa pada data validasi. Hasil pelatihan model *ResNet50* dapat dilihat pada Gambar 5 dan Gambar 6 berikut :

Epoch 1/5	
565/565	1031s 2s/step - accuracy: 0.7525 - loss: 0.6698 - val_accuracy: 0.7937 - val_loss: 0.7708
Epoch 2/5	
565/565	958s 2s/step - accuracy: 0.8006 - loss: 0.4543 - val_accuracy: 0.7642 - val_loss: 0.5377
Epoch 3/5	
565/565	912s 2s/step - accuracy: 0.8198 - loss: 0.4246 - val_accuracy: 0.7341 - val_loss: 0.5715
Epoch 4/5	
565/565	936s 2s/step - accuracy: 0.8219 - loss: 0.4188 - val_accuracy: 0.7747 - val_loss: 0.6001
Epoch 5/5	
565/565	967s 2s/step - accuracy: 0.8407 - loss: 0.3764 - val_accuracy: 0.8015 - val_loss: 0.5375

Gambar 5. Hasil Pelatihan Model



Gambar 6. Grafik Hasil Pelatihan Model


Pada *Epoch* 1, model mencapai akurasi pelatihan sebesar 75,25% dengan nilai *loss* 0,6698, sementara akurasi validasi awal cukup baik pada 79,37% dengan *loss* 0,7708. Pada *Epoch* 2, akurasi pelatihan meningkat signifikan menjadi 80,06% dengan penurunan *loss* menjadi 0,4543, dan akurasi validasi tetap kompetitif di 76,42% dengan *loss* 0,5377. Kemajuan berlanjut pada *Epoch* 3, dengan akurasi pelatihan mencapai 81,98% dan *loss* menurun ke 0,4246. Di *Epoch* 4, akurasi pelatihan mencapai 82,19%, sementara akurasi validasi meningkat ke 77,47%, meskipun terdapat sedikit kenaikan pada *loss* validasi. Pada *Epoch* 5, model mencatat performa terbaiknya dengan akurasi pelatihan tertinggi 84,07% dan penurunan *loss* hingga 0,3764, serta akurasi validasi signifikan sebesar 80,15% dengan *loss* 0,5375. Secara keseluruhan, model menunjukkan peningkatan stabil dalam performa, dengan akurasi validasi di atas 80% pada *epoch* terakhir yang mencerminkan kemampuan

model untuk memberikan prediksi andal pada data baru, memberikan dasar kuat untuk pengembangan dan optimisasi lebih lanjut.

3.5 Evaluasi Model

	precision	recall	f1-score	support
Anorganik	0.85	0.67	0.75	2000
Organik	0.78	0.91	0.84	2513
accuracy			0.80	4513
macro avg	0.81	0.79	0.79	4513
weighted avg	0.81	0.80	0.80	4513

Gambar 7. Hasil Evaluasi Model



Gambar 8. Hasil *Confusion Matrix*

Berdasarkan hasil evaluasi pada Gambar 7, model menunjukkan akurasi keseluruhan sebesar 80 %, dengan performa yang cukup baik dalam mengklasifikasikan kedua kelas, yaitu Anorganik dan Organik. Pada kelas Anorganik, *precision* sebesar 85 % menunjukkan tingkat kepercayaan yang tinggi dalam prediksi, sementara *recall* mencapai 67 %, yang mengindikasikan bahwa model berhasil mendeteksi sebagian besar sampel dari kelas ini. *F1-score* untuk kelas ini berada di angka 75 %, mencerminkan keseimbangan yang cukup baik antara *precision* dan *recall*. Dari *Confusion Matrix* pada Gambar 8, model berhasil mengklasifikasikan 1.342 sampel Anorganik dengan benar.

Pada kelas Organik, model menunjukkan performa yang sangat baik, dengan *precision* sebesar 78 % dan *recall* tinggi sebesar 91 %, menghasilkan *F1-score* sebesar 84 %. *Confusion Matrix* menunjukkan bahwa model berhasil mengklasifikasikan 2.275 sampel Organik dengan akurasi yang tinggi, menunjukkan keberhasilan besar dalam mengenali sampel dari kelas ini.

Secara keseluruhan, macro average untuk *precision*, *recall*, dan *F1-score* masing-masing berada pada angka 81 %, 79 %, dan 79 %, sedangkan *weighted average* masing-masing mencapai 81 %, 80 %, dan 80 %. Hasil ini menunjukkan bahwa model memiliki performa yang cukup seimbang antar kelas. Kategori Organik menunjukkan tingkat keberhasilan yang sangat tinggi, dengan sebagian besar sampel terklasifikasi secara akurat. Kategori Anorganik juga menunjukkan performa yang baik, meskipun masih terdapat beberapa sampel yang salah klasifikasi. Dengan sedikit peningkatan pada *recall* untuk kelas Anorganik, model memiliki potensi untuk mencapai performa klasifikasi yang lebih optimal.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa model *ResNet50* efektif untuk klasifikasi sampah organik dan anorganik, dengan akurasi validasi tertinggi mencapai 80,15%. Hasil ini sangat penting dalam

mendukung pengembangan sistem pemilahan sampah otomatis yang lebih efisien, yang dapat mempercepat proses pemilahan dan meningkatkan akurasi dalam pengelolaan sampah. Dengan demikian, teknologi ini berkontribusi pada pengelolaan sampah yang lebih ramah lingkungan, serta dapat mengurangi beban manusia dalam melakukan pemilahan sampah secara manual.

Untuk pengembangan lebih lanjut, direkomendasikan peningkatan akurasi pada kategori anorganik, yang dapat dicapai melalui pengumpulan dataset yang lebih besar, lebih beragam, dan mencakup berbagai jenis sampah anorganik yang belum cukup terwakili dalam dataset saat ini. Selain itu, integrasi model dengan perangkat *Internet of Things* (IoT) dapat diusulkan untuk aplikasi sistem pemilahan sampah secara real-time, memungkinkan pemantauan dan pengelolaan sampah yang lebih cerdas dan otomatis di berbagai lokasi, seperti di rumah, kantor, atau tempat umum. Hal ini dapat membuka potensi aplikasi sistem pemilahan sampah dalam skala yang lebih luas dan praktis.

DAFTAR PUSTAKA

- [1] E. A. Wikurendra, A. Csonka, I. Nagy, and G. Nurika, "Urbanization and Benefit of Integration Circular Economy into Waste Management in Indonesia: A Review," Jun. 01, 2024, *Springer Nature*. doi: 10.1007/s43615-024-00346-w.
- [2] Z. Wang, W. Zhou, and Y. Li, "Garbage FusionNet: A deep learning framework combining ResNet and Vision Transformer for waste classification," 2024.
- [3] T. K. Tran, K. T. Huynh, D.-N. Le, M. Arif, and H. M. Dinh, "A Deep Trash Classification Model on Raspberry Pi 4.," *Intelligent Automation & Soft Computing*, vol. 35, no. 2, 2023.
- [4] Z. Feng, J. Yang, L. Chen, Z. Chen, and L. Li, "An intelligent waste-sorting and recycling device based on improved EfficientNet," *Int J Environ Res Public Health*, vol. 19, no. 23, p. 15987, 2022.
- [5] M. M. Hossen *et al.*, "A Reliable and Robust Deep Learning Model for Effective Recyclable Waste Classification," *IEEE Access*, vol. 12, pp. 13809–13821, 2024, doi: 10.1109/ACCESS.2024.3354774.
- [6] Z. Qiao, "Advancing Recycling Efficiency: A Comparative Analysis of Deep Learning Models in Waste Classification," *arXiv preprint arXiv:2411.02779*, 2024.
- [7] O. Adedeji and Z. Wang, "Intelligent waste classification system using deep learning convolutional neural network," *Procedia Manuf*, vol. 35, pp. 607–612, 2019.
- [8] M. Liu, L. Chen, X. Du, L. Jin, and M. Shang, "Activated gradients for deep neural networks," *IEEE Trans Neural Netw Learn Syst*, vol. 34, no. 4, pp. 2156–2168, 2021.
- [9] K. M. Jon Tarnate, M. Devaraj, and J. C. De Goma, "Overcoming The Vanishing Gradient Problem Of Recurrent Neural Networks In The Iso 9001 Quality Management Audit Reports Classification," *INTERNATIONAL JOURNAL OF SCIENTIFIC & TECHNOLOGY RESEARCH*, vol. 9, no. 03, 2020, [Online]. Available: www.ijstr.org
- [10] F. Wu and H. Lin, "Effect of transfer learning on the performance of VGGNet-16 and ResNet-50 for the classification of organic and residual waste," *Front Environ Sci*, vol. 10, p. 1043843, 2022.
- [11] M.-H. Huynh, P.-T. Pham-Hoai, A.-K. Tran, and T.-D. Nguyen, "Automated waste sorting using convolutional neural network," in *2020 7th NAFOSTED Conference on Information and Computer Science (NICS)*, IEEE, 2020, pp. 102–107.
- [12] F. Wu and H. Lin, "Effect of transfer learning on the performance of VGGNet-16 and ResNet-50 for the classification of organic and residual waste," *Front Environ Sci*, vol. 10, p. 1043843, 2022.
- [13] O. Rainio, J. Teuho, and R. Klén, "Evaluation metrics and statistical tests for machine learning," *Sci Rep*, vol. 14, no. 1, p. 6086, 2024.
- [14] E. E. O. Avilés, D. Olmos-Liceaga, and J.-H. Jung, "Stratified Sampling Algorithms for Machine Learning Methods in Solving Two-scale Partial Differential Equations," *arXiv preprint arXiv:2405.15686*, 2024.

- [15] Z. Wang, Q. Xu, Z. Yang, Y. He, X. Cao, and Q. Huang, “A unified generalization analysis of re-weighting and logit-adjustment for imbalanced learning,” *Adv Neural Inf Process Syst*, vol. 36, 2024.