

Klasifikasi Sampah Menggunakan Algoritma EfficientNet

¹Putri Desi Kusuma Sari, ²Umi Mahdiyah, ³Resty Wulanningrum

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹putridesi825@gmail.com, ²umimahdiyah@gmail.com, ³restyw@unpkdr.ac.id

Penulis Korespondens : Putri Desi Kusuma Sari

Abstrak— Pengelolaan sampah yang kurang optimal berdampak negatif pada lingkungan, sehingga klasifikasi sampah menjadi penting untuk mendukung daur ulang. Penelitian ini mengembangkan sistem klasifikasi gambar sampah organik dan anorganik menggunakan model *deep learning EfficientNetB1*. Dataset sebanyak 2.527 gambar dari Kaggle diproses melalui *resize*, normalisasi, dan augmentasi. Model ini dilatih dan diuji dengan metrik akurasi, presisi, recall, dan F1-Score. Pengujian menghasilkan bahwa model mencapai akurasi rata-rata 92%, presisi 93%, recall 92%, dan F1-Score 92%. Meskipun terdapat variasi pencahayaan dan latar belakang, model mampu mengenali dua jenis sampah dengan baik. Sistem ini berpotensi diimplementasikan dalam aplikasi berbasis web untuk membantu masyarakat memilah sampah secara mandiri dan berkelanjutan.

Kata Kunci— Anorganik, *Deep Learning*, *EfficientNetB1*, Klasifikasi Sampah, Organik

Abstract— *Sub-optimal waste management has a negative impact on the environment, so waste classification is important to support recycling. This research develops an organic and inorganic waste image classification system using the EfficientNetB1 deep learning model. A dataset of 2,527 images from Kaggle was processed through resize, normalization, and augmentation. The model was trained and tested with accuracy, precision, recall, and F1-Score metrics. The tests resulted in the model achieving an average accuracy of 92%, precision of 93%, recall of 92%, and F1-Score of 92%. Despite variations in lighting and background, the model was able to recognize the two types of waste well. This system has the potential to be implemented in a web-based application to help people sort waste independently and sustainably.*

Keywords— *Inorganic, Deep Learning, EfficientNetB1, Garbage Classification, Organic*

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Sampah adalah masalah besar bagi kelestarian lingkungan dan jika tidak dikelola dengan baik, akan menyebabkan penyakit dan ketidakseimbangan di ekosistem[1]. Manusia menghasilkan berbagai jenis barang dari sumber daya alam[2] yang secara umum, sampah dapat dikategorikan menjadi dua jenis, yaitu sampah organik dan sampah anorganik[3]. Sampah organik adalah limbah yang rusak dari sisa makhluk hidup dan mudah terurai. Sedangkan sampah anorganik adalah sampah yang berasal dari sisa manusia yang sulit diuraikan oleh bakteri dan membutuhkan waktu yang lama bahkan ratusan tahun untuk diuraikan oleh bakteri, menjadikannya sampah yang ramah lingkungan[4]. Untuk pengelolaan limbah yang berkelanjutan, klasifikasi sampah yang tepat sangat penting.

Pengelolaan sampah yang kurang optimal, terutama pada tempat pembuangan akhir (TPA), menyebabkan peningkatan volume sampah yang tidak tertangani dengan baik[5]. Sementara jumlah sampah yang masuk terus meningkat setiap hari, ada beberapa tempat seperti TPA X di mana proses pemilahan sampah masih belum sempurna. Mengklasifikasikan kedua jenis sampah ini sangat penting untuk mempermudah proses daur ulang dan pengolahan lebih lanjut. Ini dapat membantu keberlanjutan lingkungan dan mengurangi beban tempat pembuangan akhir.[6].

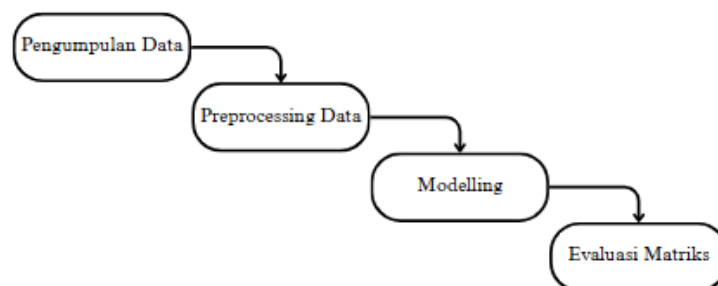
Perkembangan teknologi kecerdasan buatan, khususnya *deep learning* dalam bidang pengolahan citra digital, telah membuka peluang baru dalam otomatisasi klasifikasi sampah. Salah satu arsitektur *deep learning* yang terbukti bagus dan memiliki performa tinggi adalah *EfficientNet*. *EfficientNet* merupakan pengembangan dari jaringan *Convolutional Neural Network* (CNN) yang mengoptimalkan skala model melalui kombinasi tiga aspek utama: kedalaman (*depth*), lebar jaringan (*width*), dan resolusi input (*resolution*). Keunggulan ini membuat *EfficientNet* mampu memberikan akurasi tinggi dengan kompleksitas komputasi yang lebih ringan dibandingkan CNN konvensional.

Beberapa penelitian sebelumnya telah menunjukkan keberhasilan dalam penerapan model klasifikasi sampah berbasis CNN dan YOLO, seperti penelitian oleh [7] menggunakan CNN untuk mengklasifikasikan sampah organik dan anorganik, mencapai akurasi 94,88% pada data uji. Selain itu, sistem ini digunakan untuk aplikasi klasifikasi gambar, dengan akurasi 97,6% untuk sampah organik dan 98,4% untuk sampah anorganik, masing-masing. Peneliti [6] mengembangkan sistem klasifikasi berbasis YOLOv5 yang dapat melakukan klasifikasi secara real-time dan diintegrasikan ke dalam platform website. Model ini mencapai akurasi rata-rata sebesar 86% dengan dataset 3.000 gambar.

Tujuan dari penelitian ini adalah untuk membuat sistem klasifikasi otomatis yang dapat secara cepat dan tepat membedakan sampah organik dan anorganik sambil melakukan hal-hal yang ramah lingkungan dan mengelola sampah secara berkelanjutan. Sistem tersebut juga dapat dievaluasi dengan metrik performa seperti akurasi, presisi, *recall*, dan *F1-Score*. Sistem ini dimaksudkan untuk membuat masyarakat dapat mengaksesnya secara langsung melalui perangkat mereka, hanya dengan mengunggah gambar sampah yang ingin diklasifikasikan. Arsitektur *EfficientNetB1*, yang memiliki kinerja tinggi dan kemampuan umum, mendukung tujuan ini.

II. METODE

Untuk mengklasifikasikan sampah, penelitian ini menggunakan pendekatan komprehensif. Proses ini mencakup beberapa fase utama, yaitu pengumpulan data, *preprocessing* data, *modelling*, dan evaluasi matriks. Alur penelitian ini dicantumkan pada Gambar 1:



Gambar 1 Alur Penelitian

2.1 Pengumpulan Data

Gambar sampah diklasifikasikan ke dalam dua kelas utama yaitu sampah organik dan sampah anorganik. Data ini diperoleh dari dataset publik yang dapat diakses melalui platform Kaggle, dan totalnya adalah 2.527 gambar, termasuk 1.134 gambar yang dikategorikan sebagai sampah organik dan 1.393 gambar yang dikategorikan sebagai sampah anorganik. Dalam dataset, citra-citra menunjukkan perbedaan kondisi nyata, seperti perbedaan pencahayaan, sudut pandang, dan latar belakang. Ini dilakukan untuk meningkatkan kemampuan model untuk menemukan objek sampah dalam berbagai kondisi lingkungan. Dataset kemudian dibagi ke dalam tiga subset utama: data pelatihan (*training*), validasi (*validation*), dan uji. Rekomendasi umumnya adalah 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Berikut ini contoh hasil proses pengumpulan data yang dapat dilihat pada Gambar 2.



Sampah Organik



Sampah Anorganik

Gambar 2 Contoh Sampah Organik dan Anorganik

2.2 Preprocessing Data

Sebelum digunakan dalam proses pelatihan, seluruh gambar diproses untuk memastikan kualitas dan format data sesuai dengan kebutuhan model. Proses persiapan termasuk:

2.2.1. *Resize*: Ukuran gambar diubah menjadi 240 x 240 piksel agar sesuai dengan input yang dibutuhkan oleh arsitektur *EfficientNetB1*[8]. Jika diperlukan, ukuran gambar dapat diubah menjadi 224 x 224 piksel, tergantung pada spesifikasi arsitektur. Tujuan dari proses ini adalah untuk menyamakan dimensi input, memastikan stabilitas, dan kinerja selama pelatihan. Berikut ini hasil proses *resize* yang dapat dilihat pada Gambar 3.




Gambar 3 *Resize*

2.2.2 *Normalisasi Piksel*: Normalisasi ini mengubah nilai piksel gambar yang awalnya berada di antara 0 dan 255 ke rentang [0, 1] untuk mempercepat proses konvergensi dan membantu model memahami struktur visual gambar[9]. Berikut ini hasil proses normalisasi piksel yang dapat dilihat pada Gambar 4.



Gambar 4 Normalisasi Piksel


2.2.3 Augmentasi Data: Untuk meningkatkan variasi dataset, digunakan teknik augmentasi seperti rotasi acak, *flip horizontal*, *zoom*, dan perubahan kontras. Ini dilakukan karena jumlah data yang masih dianggap terbatas. Proses ini meningkatkan generalisasi model dan mencegah *overfitting*. Untuk meningkatkan, *library Hard* menggunakan *ImageDataGenerator*[10]. Berikut ini hasil proses augmentasi data yang dapat dilihat pada Gambar 5.



Gambar 5 Augmentasi Data

2.3 Modelling

Model yang digunakan dalam penelitian ini adalah *EfficientNet*, *EfficientNet* merupakan arsitektur CNN (*Convolutional Neural Network*) yang diperkenalkan oleh [11] dengan pendekatan yang efisien dalam memperbesar ukuran model *neural network*. *EfficientNet* menerapkan pendekatan compound scaling, yang memperbesar model secara bersama dalam tiga aspek: width (lebar), depth (kedalaman), dan resolution (resolusi input). Metode ini berbeda dengan pendekatan konvensional yang hanya meningkatkan satu dimensi model, seperti kedalaman atau lebar jaringan[12].



Gambar 6 Model Scalling

Pada Gambar 6, menunjukkan lima pendekatan scaling:

2.3.1 *Baseline*: Model dasar (misalnya *EfficientNet-B0*) dengan ukuran jaringan, jumlah channel, dan resolusi input tertentu. Ini menjadi titik awal sebelum dilakukan *scaling*.

2.3.2 *Width Scaling* (memperlebar jaringan): Jumlah filter di setiap lapisan ditingkatkan sehingga jaringan lebih lebar. Ini meningkatkan kapasitas representasi, tetapi jika hanya dilakukan sendiri dapat menyebabkan *overfitting*.

2.3.3 *Depth Scaling* (memperdalam jaringan): Menambah jumlah layer, membuat model lebih dalam. Ini memungkinkan penangkapan fitur yang lebih kompleks, tetapi tanpa kontrol dapat memperlambat pelatihan dan menyebabkan degradasi gradien.

2.3.4 *Resolution Scaling* (meningkatkan resolusi gambar): Input gambar dengan resolusi yang lebih tinggi dapat meningkatkan akurasi karena informasi detail yang lebih banyak dapat dipelajari oleh model.

2.3.5 *Compound Scaling*: Merupakan pendekatan utama *EfficientNet*. Ketiga aspek (*depth*, *width*, *resolution*) ditingkatkan secara bersamaan dengan koefisien skala yang telah dioptimalkan. Ini menghasilkan performa yang lebih tinggi dengan efisiensi komputasi yang lebih baik dibandingkan jika hanya meningkatkan salah satu aspek saja.

Adapun rumus yang digunakan di *Compound Scaling*:

$$\text{depth: } d = \alpha^\emptyset \quad (1)$$

$$\text{width: } \omega = \beta^\emptyset \quad (2)$$

$$\text{resolution: } r = \gamma^\emptyset \quad (3)$$

$$s.t. \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \quad (4)$$

$$\alpha \geq 1, \beta \geq 1, \gamma \geq 1 \quad (5)$$

Keterangan:

- (1) *Depth* : Penskalaan jumlah lapisan (*depth*) model dilakukan menggunakan faktor α yang dipangkatkan oleh \emptyset .
- (2) *Width* : Penskalaan jumlah channel (lebar *layer*) menggunakan faktor β yang dipangkatkan oleh \emptyset .
- (3) *Resolution* : Penskalaan resolusi input gambar menggunakan faktor γ yang dipangkatkan oleh \emptyset .
- (4) Kendala $\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2$: Menyatakan bahwa total peningkatan kompleksitas komputasi model mendekati dua kali lipat untuk setiap kenaikan \emptyset .
- (5) Batasan $\alpha \geq 1, \beta \geq 1, \gamma \geq 1$: Memberikan batas bawah agar tidak ada pengurangan skala pada *depth*, *width*, maupun *resolution* dari model dasar.

2.4. Evaluasi Matriks

Untuk menentukan tingkat keberhasilan dari kinerja sistem menggunakan model yang telah dilatih untuk mendeteksi objek digunakan matriks evaluasi diantaranya adalah *Accuracy*, *Precision*, *Recall*, *F1-Score*, *Confusion Matrix*. *Confusion matrix* adalah tabel yang menyatakan klasifikasi jumlah data uji yang benar dan jumlah data uji yang salah[13]. Pada tabel 1 merupakan contoh *confusion matrix*.

Tabel 1 *Confusion Matrix*

Class	Kelas Positif	Kelas Negatif
Positif	TP (<i>True Positive</i>)	TN (<i>True Negative</i>)
Negatif	FP (<i>False Positive</i>)	FN (<i>False Negative</i>)

Adapun rumus-rumus yang digunakan dalam evaluasi model:

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (6)$$

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

$$Recall = \frac{TP}{(TP+FN)} \quad (8)$$

$$F1 - Score = 2 * \frac{(Recall * Precision)}{(Recall + Precision)} \quad (9)$$

Contoh evaluasi matriks

Confusion Matrix: $\begin{bmatrix} 40 & 50 \\ 10 & 5 \end{bmatrix}$

Dimana 40 adalah TP, 50 adalah TN, 10 adalah FP, 5 adalah FN. Maka:

$$Accuracy = \frac{(TP+TN)}{(TP+FP+FN+TN)} = \frac{(40+50)}{(40+50+10+5)} = 0.8571$$


$$Precision = \frac{TP}{(TP+FP)} = \frac{40}{(40+10)} = 0.8$$

$$Recall = \frac{TP}{(TP+FN)} = \frac{40}{(40+5)} = 0.8889$$

$$F1 - Score = 2 * \frac{(Recall * Precision)}{(Recall + Precision)} = 2 * \frac{(0.8889 * 0.8)}{(0.8889 + 0.8)} = 0.8416$$

III. HASIL DAN PEMBAHASAN

Model *EfficientNet* yang telah dikembangkan dievaluasi melalui serangkaian pengujian untuk mengukur kemampuannya dalam mengklasifikasikan jenis sampah menjadi organik dan anorganik. Untuk mengukur akurasi klasifikasi antara dua kelas sampah, sampah organik dan anorganik, hasil evaluasi model *EfficientNetB1* ditampilkan dalam bentuk tabel metrik evaluasi dan *confusion matrix*.



Gambar 7 Hasil Confusion Matrix

Berdasarkan hasil evaluasi pada gambar 7, model *EfficientNetB1* dapat mengenali mayoritas gambar sampah dengan tingkat akurasi yang baik. Dari keseluruhan data uji, sebanyak 161 gambar sampah organik terklasifikasi dengan tepat (*True Positive*), sementara 10 gambar organik keliru terklasifikasi sebagai anorganik (*False Negative*). Pada kelas anorganik, 190 gambar berhasil diidentifikasi dengan tepat (*True Negative*), dan 19 gambar keliru dikategorikan sebagai

organik (*False Positive*). Ini menunjukkan bahwa model mampu membedakan kedua kelas dengan baik, meskipun masih ada kesalahan klasifikasi yang cukup minor.

Adapun perhitungan metrik evaluasi ditampilkan pada tabel 2 berikut:

Tabel 2 Classification Report

Class	Images	Accuracy	Precision	Recall	F1-Score
Anorganik	1134	0,92	0,95	0,91	0,93
Organik	1393		0,89	0,94	0,92
Macro Avg			0,92	0,93	0,92
Weightes Avg			0,93	0,92	0,92

Hasil evaluasi ini menunjukkan bahwa model memiliki kemampuan klasifikasi yang seimbang antara kedua kelas. Precision yang tinggi pada kelas anorganik (0,95) mengindikasikan bahwa prediksi terhadap gambar yang diklasifikasikan sebagai anorganik sebagian besar benar, sehingga model minim menghasilkan *false positive*. Di sisi lain, nilai recall yang tinggi pada kelas organik (0,94) menunjukkan bahwa model mampu menangkap sebagian besar gambar organik dengan benar. F1-score yang tinggi di kedua kelas (lebih dari 0,90) menunjukkan keseimbangan yang baik antara precision dan recall.

Secara keseluruhan, nilai rata-rata makro untuk semua metrik berada pada kisaran 0,92 hingga 0,93, yang menunjukkan bahwa model mampu melakukan klasifikasi secara konsisten baik pada data organik maupun anorganik. Dengan akurasi keseluruhan sebesar 92%, sistem ini menunjukkan tingkat kesalahan yang rendah meskipun gambar diuji dengan variasi kondisi pencahayaan, sudut pandang, dan latar belakang.

Keandalan model *EfficientNetB1* ini tidak lepas dari kemampuannya dalam melakukan compound scaling, yaitu peningkatan model secara seimbang dari segi kedalaman, lebar, dan resolusi input. Hal ini menjadikannya unggul dibandingkan arsitektur CNN konvensional yang hanya meningkatkan satu dimensi saja. Model ini juga memiliki jumlah parameter yang relatif lebih efisien, sehingga cocok untuk diintegrasikan dalam aplikasi berbasis web yang dapat diakses oleh masyarakat umum.

Implikasi dari keberhasilan model ini sangat penting dalam mendukung upaya pengelolaan sampah berkelanjutan. Dengan menyediakan sistem klasifikasi otomatis berbasis citra, masyarakat dapat dengan mudah memilah sampah hanya dengan mengunggah gambar melalui perangkat digital. Hal ini tidak hanya meningkatkan kesadaran lingkungan, tetapi juga membantu mengurangi beban tempat pembuangan akhir dan mendukung proses daur ulang yang lebih optimal.

IV. KESIMPULAN

Penelitian ini mengembangkan sistem klasifikasi sampah organik dan anorganik yang berbasis *EfficientNetB1* dan dapat digunakan melalui aplikasi web. Hasil evaluasi menunjukkan bahwa model dapat mengklasifikasikan gambar sampah dengan keakuratan yang tinggi bahkan pada data yang memiliki variasi latar belakang dan pencahayaan, dengan akurasi rata-rata sebesar 92%, presisi sebesar 93%, recall sebesar 92%, dan F1-Score sebesar 92%. Diharapkan sistem ini akan menjadi solusi praktis yang mendorong masyarakat untuk menjadi lebih ramah lingkungan dan membantu mereka memilah sampah secara mandiri dan lebih efisien.

DAFTAR PUSTAKA

- [1] J. Pandu Hidayat *et al.*, “Pemanfaatan sampah organik-anorganik menjadi kompos dan ecobrick paguyuban Batu Ampar RT 17 Balikpapan,” *SELAPARANG: Jurnal Pengabdian Masyarakat Berkemajuan*, vol. 8, no. 2, pp. 1283–1296, 2024.
- [2] A. Nurdin *et al.*, “Pengaruh Sampah Organik, Anorganik dan Bahan Berbahaya dan Beracun (B3) terhadap Kesehatan pada Pekerja di Tempat Pemrosesan Akhir (TPA) Gampong Jawa Kota Banda Aceh”, [Online]. Available: <http://jurnal.abulyatama.ac.id/acehmedika>
- [3] 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.
- [4] R. Batubara, R. Mardiansyah, and A. Sukma, “PENGADAAN TONG SAMPAH ORGANIK DAN ANORGANIK DIKELURAHAN INDRO KECAMATAN KEBOMAS GRESIK,” *Journal of Community Service*, vol. 4, no. 1, 2022.
- [5] A. A. Fathurrahman and F. Akbar, “Perancangan Sistem Identifikasi Jenis Sampah Menggunakan Tensorflow Object Detection Dan Transfer Learning,” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 10, no. 1, pp. 64–71, May 2024, doi: 10.25077/teknosi.v10i1.2024.64-71.
- [6] H. Abdillah, A. Naufal Syahbana, G. Ishaq, A. Husain, and S. Agustin, “Detektif Sampah : Klasifikasi Jenis Sampah Organik dan Anorganik Menggunakan Metode YOLOv5 Berbasis Website,” 2024.
- [7] M. E. Purba, A. Z. Situmorang, G. L. Br Ginting, M. W. P. Lubis, and F. M. Sinaga, “Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN,” *Jurnal Sifo Mikroskil*, vol. 26, no. 1, pp. 37–54, Apr. 2025, doi: 10.55601/jsm.v26i1.1510.
- [8] A. A. RAHMAN, S. D. AGUSTIN, N. IBRAHIM, and N. C. KUMALASARI, “Perbandingan Algoritma YOLOv4 dan Scaled YOLOv4 untuk Deteksi Objek pada Citra Termal,” *MIND Journal*, vol. 7, no. 1, pp. 61–71, Jun. 2022, doi: 10.26760/mindjournal.v7i1.61-71.
- [9] K. Umam, “MIND (Multimedia Artificial Intelligent Networking Database Perbandingan Metode ARIMA dan LSTM pada Prediksi Jumlah Pengunjung Perpustakaan,” *Journal MIND Journal | ISSN*, vol. 8, no. 2, pp. 119–129, 2023, doi: 10.26760/mindjournal.v8i2.119-129.
- [10] A. I. Hanifah and A. Hermawan, “Klasifikasi Kematangan Pisang Menggunakan Metode Convolutional Neural Network,” *Komputika : Jurnal Sistem Komputer*, vol. 12, no. 2, pp. 49–56, Sep. 2023, doi: 10.34010/komputika.v12i2.9999.
- [11] M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” May 2019, [Online]. Available: <http://arxiv.org/abs/1905.11946>
- [12] N. A. Choirunisa, T. Karlita, and R. Asmara, “Deteksi Ras Kucing Menggunakan Compound Model Scaling Convolutional Neural Network,” *Technomedia Journal*, vol. 6, no. 2 Februari, pp. 236–251, 2022.
- [13] F. Bimantoro, R. Nisful, L. Hidayah, and D. Swanjaya, “Komparasi Algoritma MLP+LBP dan CNN Sebagai solusi Inovatif Untuk Deteksi Dini Korosi,” Online, 2024.