

Klasifikasi Sampah Styrofoam Menggunakan Efficientnet Berbasis Deep Learning dengan Pendekatan Transfer Learning

Nabella Hermy Nathania¹, Erwin Dwika Putra^{2*}, Yulia Darmi³, Muntahanah⁴

^{1,2,3,4}Program Studi Teknik Informatika, Fakultas Teknik,

Universitas Muhammadiyah Bengkulu, Indonesia

¹nabellaherninathania@gmail.com; ²erwindwikap@gmail.com; ³yuliadarmi@umb.ac.id; ⁴muntahanah@umb.ac.id

Abstrak.

Tujuan : Permasalahan penumpukan sampah styrofoam yang sulit terurai secara alami menuntut adanya inovasi dalam sistem pengelolaan sampah yang cepat, akurat, dan otomatis. Teknologi *computer vision* berbasis *deep learning* menawarkan solusi yang adaptif dalam proses pemilahan visual, namun implementasinya sering kali terhambat oleh keterbatasan ukuran dataset dan kapasitas komputasi perangkat.

Metode/Design/Pendekatan: Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi kinerja arsitektur EfficientNet-B0 menggunakan pendekatan transfer learning untuk mengklasifikasikan sampah secara biner (*Styrofoam* dan *Non-Styrofoam*). Dataset penelitian yang digunakan terdiri dari 876 citra yang dioptimasi melalui teknik augmentasi data spasial tanpa melibatkan manipulasi *vertical flip* guna mempertahankan representasi orientasi fisik objek di dunia nyata. Untuk membuktikan efisiensi arsitektur, dilakukan eksperimen komparatif dengan perluasan skala jaringan (*network scaling*) pada varian EfficientNet-B1 dan EfficientNet-B2.

Hasil/Temuan: Hasil pengujian independen menunjukkan bahwa EfficientNet-B0 berhasil meraih performa terbaik dengan tingkat akurasi mencapai 94,70% dan nilai loss 0,2199. Sebaliknya, varian yang lebih kompleks justru mengalami penurunan performa, yaitu EfficientNet-B1 (92,42%) dan EfficientNet-B2 (93,94%).

Kebaharuan/Originalitas/Nilai: Berdasarkan hasil empiris tersebut, disimpulkan bahwa arsitektur dasar EfficientNet-B0 merupakan model yang paling optimal, ringan (*lightweight*), dan stabil untuk dataset biner berskala menengah. Temuan ini memberikan justifikasi kuat bahwa model EfficientNet-B0 sangat siap dan potensial untuk diintegrasikan pada sistem Smart Waste Management berbasis *edge computing*.

Keywords: Deep Learning, EfficientNet, Klasifikasi Sampah, Styrofoam, Transfer Learning

Abstract.

Purpose: The accumulation of Styrofoam waste, which is difficult to decompose naturally, necessitates innovations in waste management systems that are fast, accurate, and automated. Deep learning-based computer vision technology offers an adaptive solution for visual waste sorting; however, its implementation is often constrained by limited dataset sizes and device computational resources.

Methods/Study design/approach: This study aims to implement and evaluate the performance of the EfficientNet-B0 architecture using a transfer learning approach for binary waste classification (*Styrofoam* and *Non-Styrofoam*). The dataset consists of 876 images, which are augmented using spatial data augmentation techniques without vertical flipping to preserve the physical orientation of objects in real-world conditions. To evaluate architectural efficiency, comparative experiments are conducted by scaling the network using the EfficientNet-B1 and EfficientNet-B2 variants.

Result/Findings: Independent testing shows that EfficientNet-B0 achieves the best performance, with an accuracy of 94.70% and a loss value of 0.2199. In contrast, the more complex variants exhibit lower accuracy, with EfficientNet-B1 achieving 92.42% and EfficientNet-B2 achieving 93.94%.

Novelty/Originality/Value: Based on the empirical findings, EfficientNet-B0 is identified as the most suitable, lightweight, and stable architecture for the medium-scale binary dataset used in this study. These findings highlight the potential of EfficientNet-B0 for integration into edge computing-based smart waste management systems, although further evaluation under real-world conditions is necessary to validate its practical applicability.

Keywords: Deep Learning, EfficientNet, Waste Classification, Styrofoam, Transfer Learning

Article history:

Received, 2026-08-28

Revised, 2026-09-07

Accepted, 2026-10-14

*Corresponding author.

Erwin Dwika Putra

Email addresses: erwindwikap@gmail.com

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-nc-nd/4.0/) license.



PENDAHULUAN

Permasalahan sampah merupakan salah satu isu lingkungan global yang terus meningkat seiring pertumbuhan penduduk, urbanisasi, dan konsumsi produk sekali pakai. Pengelolaan sampah yang tidak optimal dapat menyebabkan pencemaran tanah, air, dan udara serta berdampak terhadap kesehatan masyarakat [1], [2]. Oleh karena itu, sistem pengelolaan sampah membutuhkan proses pemilahan yang cepat, akurat, dan otomatis untuk meningkatkan efektivitas daur ulang serta mengurangi dampak lingkungan [3], [4].

Salah satu jenis sampah yang menjadi perhatian adalah styrofoam yang berbahan dasar polystyrene dan banyak digunakan sebagai wadah makanan, pelindung barang, serta kemasan sekali pakai. Sifatnya yang ringan, sulit terurai, dan sulit diproses melalui sistem daur ulang konvensional menyebabkan styrofoam berpotensi mencemari lingkungan dalam jangka panjang dan berakhir di tempat pembuangan akhir (TPA). Kondisi tersebut menunjukkan pentingnya pengembangan sistem identifikasi dan klasifikasi styrofoam secara otomatis untuk mendukung pemilahan sampah yang lebih efektif [5], [6].

Sejalan dengan kemajuan teknologi terapan di bidang kecerdasan buatan, teknologi computer vision dan deep learning semakin banyak dimanfaatkan untuk mengotomatisasi proses identifikasi dan klasifikasi objek berdasarkan karakteristik visualnya. Penerapan teknologi tersebut pada pengelolaan sampah dapat menjadi solusi untuk meningkatkan kecepatan dan ketepatan proses pemilahan sekaligus mengurangi ketergantungan terhadap proses manual. Deep learning mampu melakukan ekstraksi fitur citra secara otomatis dan memberikan kemampuan klasifikasi yang lebih baik dibandingkan pendekatan machine learning konvensional [7]. Penelitian sebelumnya menunjukkan bahwa metode deep learning memiliki kemampuan tinggi dalam mengenali objek sampah berdasarkan karakteristik visual citra [8], [9].

Salah satu pendekatan deep learning yang banyak digunakan untuk klasifikasi citra adalah Convolutional Neural Network (CNN), dengan arsitektur seperti VGG16, ResNet50, MobileNetV2, dan DenseNet. VGG16 memiliki struktur yang sederhana tetapi membutuhkan parameter besar, sedangkan ResNet50 mampu mengatasi vanishing gradient melalui residual connection namun memiliki kompleksitas komputasi relatif tinggi (Simonyan and Zisserman, 2015; He *et al.*, 2016). MobileNetV2 lebih ringan dan sesuai untuk perangkat dengan sumber daya terbatas, tetapi dapat mengalami penurunan akurasi pada objek dengan karakteristik visual yang mirip. [11], [12]. DenseNet memiliki kemampuan *feature propagation* yang baik, tetapi membutuhkan penggunaan memori yang lebih besar ketika jumlah layer meningkat [13].

Sebagai alternatif, arsitektur EfficientNet menjadi salah satu model *deep learning* yang menunjukkan performa sangat baik pada berbagai tugas klasifikasi citra. EfficientNet menggunakan metode *compound scaling* yang menyeimbangkan skala *depth*, *width*, dan *resolution* jaringan secara optimal sehingga mampu menghasilkan akurasi tinggi dengan jumlah parameter yang lebih efisien [14]. EfficientNet juga dikenal memiliki performa yang baik pada dataset berukuran terbatas karena didukung pendekatan *transfer learning* dari model pretrained ImageNet [15].

EfficientNet memiliki keunggulan berupa ukuran model yang relatif ringan, kebutuhan komputasi lebih rendah, proses training yang efisien, serta kemampuan generalisasi yang baik pada dataset kecil hingga menengah [16]. Penerapan EfficientNet pada klasifikasi sampah juga menunjukkan performa yang tinggi melalui kombinasi *transfer learning* dan data *augmentation* [17], [18]. Selain itu, EfficientNetB0 memiliki performa yang lebih stabil dibandingkan beberapa arsitektur CNN lain pada proses klasifikasi citra berbasis *transfer learning* [19].


Penelitian ini menggunakan EfficientNetB0 dengan pendekatan *transfer learning* untuk mengklasifikasikan sampah styrofoam. Pendekatan tersebut memanfaatkan bobot pretrained dari ImageNet sehingga sesuai untuk dataset yang relatif terbatas [20]. Dataset penelitian terdiri atas 876 citra, yaitu 438 citra styrofoam dan 438 citra non-styrofoam. Untuk meningkatkan variasi data pelatihan dan kemampuan generalisasi model, diterapkan data *augmentation* berupa rotasi, zoom, *flipping*, dan *brightness adjustment* [21], [22].

Klasifikasi biner antara styrofoam dan non-styrofoam dipilih agar model dapat berfokus pada karakteristik visual styrofoam dengan proses pelatihan yang lebih sederhana. EfficientNetB0 digunakan karena memiliki arsitektur yang ringan dan efisien sehingga berpotensi diterapkan pada perangkat dengan sumber daya komputasi terbatas [14], [23]. Selain itu, penelitian dapat diperluas melalui perbandingan EfficientNetB0, EfficientNetB1, dan EfficientNetB2 untuk mengetahui pengaruh perbedaan kompleksitas arsitektur terhadap performa klasifikasi berdasarkan *accuracy*, *precision*, *recall*, *F1-score*, dan efisiensi komputasi [14], [15], [16].

Berdasarkan latar belakang tersebut, penelitian ini dilakukan dengan judul “Klasifikasi Sampah Styrofoam Menggunakan EfficientNet Berbasis Deep Learning dengan Pendekatan Transfer Learning”. Penelitian ini bertujuan mengimplementasikan arsitektur EfficientNetB0 berbasis deep learning dengan pendekatan transfer learning untuk melakukan klasifikasi sampah styrofoam secara otomatis.

METODE PENELITIAN

Tahapan penelitian ini disusun secara sistematis untuk memastikan seluruh tahapan pengerjaan berjalan secara terstruktur dan terukur. Alur pelaksanaan penelitian yang meliputi pencarian landasan teori, pengolahan data citra, pengembangan model deep learning, hingga penarikan kesimpulan disajikan secara komprehensif pada Gambar 1.



Gambar 1 Alur Penelitian

Tahap awal penelitian dimulai dengan melakukan Studi Literatur menggunakan metode Systematic Literature Review (SLR). Proses ini difokuskan pada pengumpulan, penyaringan, dan analisis artikel ilmiah serta dokumen akademis yang relevan dengan topik klasifikasi sampah, teknologi deep learning, pendekatan transfer learning, serta arsitektur EfficientNet. Tahapan ini krusial untuk membangun fondasi teori yang kuat, memahami perkembangan penelitian terkini, serta mengidentifikasi celah riset yang dapat diselesaikan. Setelah landasan teori terbentuk, dilakukan tahapan pengumpulan data berupa pemenuhan kebutuhan dataset citra. Dataset yang digunakan dalam penelitian ini terdiri dari total 876 citra yang didistribusikan secara seimbang ke dalam dua kelas utama. Distribusi tersebut mencakup 438 citra untuk kelas Styrofoam dan 438 citra untuk kelas Non-Styrofoam. Keseimbangan jumlah data antar kelas ini ditujukan untuk menghindari potensi bias pada model saat proses pembelajaran.

Data citra mentah yang telah dikumpulkan kemudian masuk ke tahap pra-pemrosesan guna meningkatkan kualitas visual dan menyamakan format input model. Langkah pertama adalah melakukan resize ukuran citra menjadi 224 x 224 piksel agar sesuai dengan standar dimensi input arsitektur yang digunakan. Selanjutnya, diterapkan teknik Data Augmentation melalui variasi rotasi, flip, zoom, dan manipulasi brightness untuk memperkaya variasi data secara sintetis. Tahap ini ditutup dengan melakukan normalisasi nilai piksel ke rentang 0 hingga 1 guna mempercepat proses konvergensi saat pelatihan.

Dataset yang telah melalui tahap pra-pemrosesan kemudian dibagi menggunakan metode Stratified Split. Pendekatan stratifikasi ini menjamin bahwa proporsi kelas Styrofoam dan Non-Styrofoam tetap seimbang di

setiap subset data. Alokasi pembagian data diatur dengan komposisi 70% sebagai Data Training (613 citra) untuk proses pembelajaran model, 15% sebagai Data Validation (131 citra) untuk memantau performa model saat pelatihan, dan 15% sisanya sebagai Data Testing (132 citra) yang digunakan untuk menguji kemampuan generalisasi model secara independen.

Tahap pengembangan model mengadopsi pendekatan Transfer Learning memanfaatkan arsitektur EfficientNet-B0 yang telah dilatih menggunakan dataset skala besar ImageNet. Dalam arsitektur ini, sebagian besar lapisan awal dibekukan (freeze) untuk bertindak sebagai ekstraktor fitur bawaan (feature extractor). Sementara itu, lapisan akhir model dikonfigurasi agar dapat dilatih kembali (trainable) melalui proses fine-tuning. Struktur akhir model dirancang secara khusus menggunakan susunan Global Average Pooling, Dropout untuk mencegah overfitting, Dense layer, serta fungsi aktivasi Softmax untuk menghasilkan probabilitas klasifikasi final.

Model yang telah dirancang kemudian memasuki tahap pelatihan menggunakan parameter konfigurasi yang optimal. Proses komputasi dijalankan menggunakan optimizer Adam dengan parameter learning rate sebesar $1e-4$ dan fungsi kerugian Categorical Crossentropy. Pelatihan dilakukan dengan ukuran batch (batch size) sebesar 32 serta direncanakan berjalan hingga 50 epoch. Untuk menjaga efisiensi komputasi dan menghindari overfitting, mekanisme Early Stopping diintegrasikan sepanjang proses pelatihan dengan metrik akurasi (accuracy) sebagai indikator performa utamanya. Setelah proses pelatihan selesai, performa model diuji secara menyeluruh pada tahap evaluasi menggunakan Data Testing. Matriks evaluasi yang digunakan meliputi pembuatan Confusion Matrix untuk memetakan prediksi benar dan salah, serta perhitungan nilai Accuracy, Precision, Recall, dan F1-Score. Selain itu, analisis kemampuan diskriminasi model diukur melalui kurva Receiver Operating Characteristic (ROC) beserta nilai Area Under the Curve (AUC). Evaluasi ini juga mencakup analisis visual terhadap grafik tren loss dan accuracy yang dihasilkan selama masa pelatihan.

Tahap akhir dari tahapan penelitian ini adalah analisis menyeluruh dan penarikan kesimpulan. Pada tahap ini, seluruh hasil evaluasi kuantitatif diinterpretasikan secara mendalam untuk menilai sejauh mana efektivitas model yang dikembangkan dalam menyelesaikan masalah klasifikasi sampah. Peneliti juga melakukan komparasi kinerja model terhadap parameter pengujian yang ada, mengidentifikasi kelebihan serta keterbatasan sistem, dan merumuskan kesimpulan akhir serta rekomendasi atau saran yang relevan untuk pengembangan penelitian di masa mendatang.

HASIL DAN PEMBAHASAN

Penelitian ini mengimplementasikan klasifikasi citra sampah menggunakan arsitektur EfficientNet dengan pendekatan transfer learning untuk membedakan dua kelas, yaitu Styrofoam dan Non-Styrofoam. Dataset yang digunakan terdiri atas 876 citra, dengan distribusi seimbang sebanyak 438 citra untuk setiap kelas. Hasil validasi dataset menunjukkan bahwa tidak ditemukan berkas citra rusak, berkas non-gambar, maupun citra duplikat berdasarkan pemeriksaan hash SHA-256. Kondisi tersebut menunjukkan bahwa dataset telah memenuhi pemeriksaan integritas sebelum digunakan dalam proses pelatihan model.

Sebelum pelatihan, seluruh citra diubah ukurannya menjadi 224×224 piksel dan dinormalisasi. Dataset kemudian dibagi menggunakan metode stratified split dengan proporsi 70% data pelatihan, 15% data validasi, dan 15% data pengujian. Augmentasi diterapkan pada data pelatihan melalui rotasi, pergeseran posisi, horizontal flip, zoom, dan penyesuaian kecerahan. Teknik vertical flip tidak digunakan untuk mempertahankan orientasi objek yang lebih representatif terhadap kondisi pemilahan sampah sebenarnya. Model dikembangkan dengan memanfaatkan bobot prelatih ImageNet, kemudian disesuaikan untuk klasifikasi biner.

Hasil pelatihan menunjukkan bahwa EfficientNet-B0 mampu mempelajari karakteristik visual kedua kelas dengan baik. Model menghasilkan akurasi sebesar 96,06% pada data pelatihan dan 94,66% pada data validasi. Pada pengujian independen, model memperoleh akurasi sebesar 94,70% dengan nilai loss 0,2199. Ringkasan hasil tersebut disajikan pada Tabel 1.

Tabel 1. Hasil Evaluasi EfficientNet-B0

Subset data	Akurasi (%)	Loss
Pelatihan	96,06	0,1633
Validasi	94,66	0,2150
Pengujian	94,70	0,2199

Berdasarkan Tabel 1, selisih akurasi antara data pelatihan dan pengujian sebesar 1,36 poin persentase, sedangkan selisih antara data validasi dan pengujian hanya 0,04 poin persentase. Kedekatan hasil validasi dan pengujian mengindikasikan bahwa performa model relatif konsisten pada data yang tidak digunakan untuk memperbarui bobot selama pelatihan. Nilai loss pengujian yang tetap rendah juga mendukung temuan tersebut. Meskipun

demikian, konsistensi ini belum cukup untuk menyimpulkan bahwa model sepenuhnya bebas dari overfitting, terutama karena evaluasi dilakukan pada dataset yang relatif terbatas.


Performa tersebut didukung oleh penggunaan transfer learning yang memungkinkan model memanfaatkan fitur visual dari bobot prelatih ImageNet. Penyesuaian lapisan klasifikasi dan penerapan augmentasi data membantu model mempelajari variasi posisi, ukuran, dan tampilan objek. Selain itu, penggunaan Early Stopping dan ReduceLROnPlateau membantu mengendalikan proses pelatihan ketika peningkatan performa mulai mengalami stagnasi.

Evaluasi menggunakan confusion matrix dilakukan untuk mengetahui distribusi prediksi benar dan salah pada masing-masing kelas. Dari 132 citra pengujian, model berhasil mengklasifikasikan 65 citra Non-Styrofoam dengan benar dan satu citra sebagai Styrofoam. Sementara itu, dari 66 citra aktual Styrofoam, sebanyak 60 citra berhasil dikenali dengan benar, sedangkan enam citra diklasifikasikan sebagai Non-Styrofoam.

Tabel 2. Confusion Matrix EfficientNet-B0

Kelas aktual	Prediksi Styrofoam	Prediksi Non-Styrofoam
Styrofoam	60	6
Non-Styrofoam	1	65

Berdasarkan Tabel 2, model menunjukkan kemampuan klasifikasi yang baik pada kedua kelas. Namun, terdapat perbedaan sensitivitas dalam mengenali objek. Kelas Non-Styrofoam memiliki recall sebesar 98,48%, sedangkan kelas Styrofoam memiliki recall sebesar 90,91%. Artinya, model lebih konsisten dalam mengenali sampah non-styrofoam dibandingkan mendeteksi seluruh sampel styrofoam yang tersedia.



Gambar 2 Confusion Matrix


Nilai precision sebesar 98,36% pada kelas Styrofoam menunjukkan bahwa hampir seluruh prediksi styrofoam yang dihasilkan model sesuai dengan label aktualnya. Sebaliknya, recall sebesar 90,91% memperlihatkan bahwa masih terdapat sebagian sampel styrofoam yang tidak berhasil dikenali. Pola ini menunjukkan bahwa kesalahan klasifikasi lebih banyak terjadi ketika objek styrofoam diprediksi sebagai non-styrofoam daripada kesalahan sebaliknya.

Tabel 3. Classification Report EfficientNet-B0

Kelas	Precision (%)	Recall (%)	F1-score (%)	Support
Non-Styrofoam	91,55	98,48	94,89	66
Styrofoam	98,36	90,91	94,49	66
Rata-rata makro	94,96	94,70	94,69	132

Dalam konteks pemilahan sampah otomatis, kesalahan tersebut perlu diperhatikan karena sampah styrofoam yang tidak teridentifikasi berpotensi masuk ke kategori yang keliru. Perbedaan warna, tekstur permukaan, bentuk objek, dan karakteristik latar belakang merupakan aspek visual yang perlu dievaluasi lebih lanjut. Oleh karena itu, pengembangan berikutnya dapat diarahkan pada penambahan sampel styrofoam dengan variasi bentuk dan kondisi fisik yang lebih luas.

Selain menggunakan metrik berbasis confusion matrix, kemampuan model dalam membedakan kelas dievaluasi melalui kurva Receiver Operating Characteristic (ROC) dan nilai Area Under the Curve (AUC). Berdasarkan hasil pengujian, EfficientNet-B0 memperoleh nilai AUC sebesar 0,9796.



Gambar 3 Grafik ROC dan AUC

Nilai AUC yang mendekati 1 menunjukkan kemampuan diskriminasi yang sangat baik antara kelas Styrofoam dan Non-Styrofoam. Hasil ini memperkuat temuan dari nilai akurasi sebesar 94,70%, karena evaluasi ROC-AUC mengukur kemampuan pemisahan kelas pada berbagai nilai ambang keputusan, bukan hanya pada satu ambang klasifikasi. Meskipun demikian, nilai AUC yang tinggi tidak menghilangkan kemungkinan kesalahan klasifikasi pada sampel tertentu. Hal ini terlihat dari enam citra styrofoam yang masih diprediksi sebagai non-styrofoam. Dengan demikian, interpretasi AUC perlu dilakukan bersama-sama dengan confusion matrix, precision, recall, dan F1-score agar performa model dapat dinilai secara lebih menyeluruh..

Untuk mengetahui pengaruh peningkatan skala arsitektur terhadap kinerja klasifikasi, penelitian ini membandingkan EfficientNet-B0, EfficientNet-B1, dan EfficientNet-B2. Ketiga varian digunakan untuk menyelesaikan tugas klasifikasi biner dengan memanfaatkan pendekatan transfer learning. Hasil pengujian dirangkum pada Tabel 4.

Tabel 4. Perbandingan Kinerja Varian EfficientNet

Arsitektur	Akurasi (%)	Loss pengujian
EfficientNet-B0	94,70	0,2199
EfficientNet-B1	92,42	0,2104
EfficientNet-B2	93,94	0,2180

Berdasarkan Tabel 4, EfficientNet-B0 memperoleh akurasi tertinggi sebesar 94,70%, diikuti EfficientNet-B2 sebesar 93,94% dan EfficientNet-B1 sebesar 92,42%. Selisih akurasi EfficientNet-B0 terhadap EfficientNet-B1 mencapai 2,28 poin persentase, sedangkan terhadap EfficientNet-B2 sebesar 0,76 poin persentase. Hasil ini menunjukkan bahwa peningkatan kompleksitas jaringan tidak secara otomatis meningkatkan akurasi klasifikasi pada dataset yang digunakan. Menariknya, EfficientNet-B1 menghasilkan nilai loss pengujian terendah, yaitu 0,2104, tetapi akurasinya juga merupakan yang terendah di antara ketiga model. Perbedaan tersebut menunjukkan bahwa nilai loss dan akurasi mengukur aspek performa yang berbeda. Loss mengevaluasi kualitas probabilitas prediksi berdasarkan fungsi kerugian, sedangkan akurasi mengukur proporsi prediksi yang benar setelah keputusan kelas ditentukan. Oleh sebab itu, model dengan loss lebih rendah tidak selalu menghasilkan akurasi tertinggi.

Keunggulan akurasi EfficientNet-B0 mengindikasikan bahwa kapasitas model ini lebih sesuai dengan karakteristik dan jumlah data penelitian. Dengan 876 citra, model yang lebih kompleks belum tentu memperoleh manfaat optimal dari tambahan kapasitas representasi. Salah satu kemungkinan yang perlu diuji lebih lanjut adalah bahwa varian B1 dan B2 membutuhkan dataset yang lebih besar dan beragam agar peningkatan kapasitas jaringan dapat memberikan keuntungan yang konsisten. Namun, hasil penelitian ini belum membuktikan secara langsung bahwa penurunan akurasi pada kedua varian tersebut disebabkan oleh overfitting, sehingga penjelasan tersebut perlu diperlakukan sebagai interpretasi yang masih memerlukan pengujian tambahan.

KESIMPULAN

Berdasarkan hasil implementasi, pengujian, dan analisis komparatif, penelitian ini berhasil menerapkan arsitektur EfficientNet berbasis deep learning dengan pendekatan transfer learning menggunakan bobot pretrained ImageNet untuk mengklasifikasikan sampah styrofoam dan non-styrofoam berdasarkan 876 citra. Penerapan augmentasi data berupa rotasi, pergeseran (shifting), dan perbesaran (zooming) tanpa menggunakan vertical flip dilakukan untuk meningkatkan variasi data sekaligus mempertahankan representasi orientasi objek yang realistis. Hasil pengujian terhadap 132 citra independen menunjukkan bahwa EfficientNet-B0 memperoleh akurasi sebesar

94,70%, dengan nilai loss 0,2199, serta nilai precision dan recall masing-masing sebesar 91,55% dan 98,48% untuk kelas non-styrofoam, serta 98,36% dan 90,91% untuk kelas styrofoam. Kemampuan model dalam membedakan kedua kelas juga ditunjukkan oleh nilai AUC sebesar 0,9796. Pada eksperimen komparatif, EfficientNet-B0 menghasilkan akurasi lebih tinggi dibandingkan EfficientNet-B1 sebesar 92,42% dan EfficientNet-B2 sebesar 93,94%, meskipun EfficientNet-B1 memiliki nilai loss lebih rendah, yaitu 0,2104. Hasil ini menunjukkan bahwa peningkatan kompleksitas arsitektur tidak selalu meningkatkan akurasi klasifikasi pada dataset yang terbatas. Dengan demikian, EfficientNet-B0 menjadi pilihan yang sesuai untuk penelitian ini karena mampu menghasilkan performa klasifikasi yang tinggi dengan arsitektur yang relatif ringan serta berpotensi dikembangkan untuk mendukung sistem Smart Waste Management. Namun, pengujian lebih lanjut menggunakan dataset yang lebih beragam dan kondisi lingkungan nyata diperlukan untuk mengevaluasi kemampuan generalisasi model secara lebih menyeluruh.

REFERENSI

- [1] D. Verber, T. Grneva, and J. Dugonik, "Image-Based Waste Classification Using a Hybrid Deep Learning Architecture with Transfer Learning and Edge AI Deployment," *Mathematics*, vol. 14, no. 7, p. 1176, Apr. 2026, doi: 10.3390/math14071176.
- [2] G. S. Luís, A. J. S. C. Pereira, J. Carvalho, and L. F. Neves, "Validation of a new sampler for radon gas measurements in surface water," *MethodsX*, vol. 13, p. 102815, Dec. 2024, doi: 10.1016/j.mex.2024.102815.
- [3] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, "Review of Image Classification Algorithms Based on Convolutional Neural Networks," *Remote Sens.*, vol. 13, no. 22, p. 4712, Nov. 2021, doi: 10.3390/rs13224712.
- [4] V. Jayaraman and A. R. Lakshminarayanan, "MSW-Net: A hierarchical stacking model for automated municipal solid waste classification," *J. Air Waste Manage. Assoc.*, vol. 74, no. 8, pp. 569–580, Aug. 2024, doi: 10.1080/10962247.2024.2370958.
- [5] M. S. Bin Islam *et al.*, "ECCDN-Net: A deep learning-based technique for efficient organic and recyclable waste classification," *Waste Manag.*, vol. 193, pp. 363–375, Feb. 2025, doi: 10.1016/j.wasman.2024.12.023.
- [6] M. K. Hasan, M. A. Khan, G. F. Issa, A. Atta, A. S. Akram, and M. Hassan, "Smart Waste Management and Classification System for Smart Cities using Deep Learning," in *2022 International Conference on Business Analytics for Technology and Security (ICBATS)*, IEEE, Feb. 2022, pp. 1–7. doi: 10.1109/ICBATS54253.2022.9759087.
- [7] J. Heaton, "Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning," *Genet. Program. Evolvable Mach.*, vol. 19, no. 1–2, pp. 305–307, Jun. 2018, doi: 10.1007/s10710-017-9314-z.
- [8] D. Shafek, H. W. Hilow, and M. Ahmed, "Classification of waste images using deep learning technique," *J. Appl. Res. Technol.*, vol. 23, no. 4, pp. 381–391, Aug. 2025, doi: 10.22201/icat.24486736e.2025.23.4.2578.
- [9] M. Haqqi, L. Rochmah, A. D. Safitri, R. A. Pratama, and Tarwoto, "Implementation Of Machine Learning To Identify Types Of Waste Using CNN Algorithm," *J. FASILKOM*, vol. 14, no. 3, pp. 761–765, Dec. 2024, doi: 10.37859/jf.v14i3.8116.
- [10] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *Int. Conf. Learn. Represent.*, 2015.
- [11] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.
- [12] M. G. Somoal and A. R. Dzirkillah, "Komparasi MobileNETV2 dengan Kustomisasi Transfer Learning dan Hyperparameter untuk Identifikasi Tumor Otak," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 1, pp. 229–240, Feb. 2025, doi: 10.25126/jtiik.2025129582.
- [13] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," *IEEE Access*, Jan. 2018, [Online]. Available: <http://arxiv.org/abs/1608.06993>
- [14] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," Sep. 2020, [Online]. Available: <http://arxiv.org/abs/1905.11946>
- [15] T. Kurniawan, K. Khadijah, and R. Kusumaningrum, "An Efficient Model for Waste Image Classification Using EfficientNet-B0," *J. Tek. Inform.*, vol. 6, no. 3, pp. 1147–1158, Jun. 2025, doi: 10.52436/1.jutif.2025.6.3.4417.
- [16] W. Qiu, C. Xie, and J. Huang, "An improved EfficientNetV2 for garbage classification," Mar. 2025, [Online]. Available: <http://arxiv.org/abs/2503.21208>
- [17] S. Agustiani, H. Haryani, A. Junaidi, R. R. Putri, and M. G. Adam Z, "Comparative Optimization of

- EfficientNetB3, MobileNetV2, and ResNet50 for Waste Classification,” *J. Inform.*, vol. 12, no. 2, pp. 131–137, Oct. 2025, doi: 10.31294/inf.v12i2.27533.
- [18] W. M. Ardana, “Optimization of Convolutional Neural Network Algorithm with Efficientnet-B0 and Resnet-50 Architecture for Waste Type Classification Optimasi Algoritma Convolutional Neural Network dengan Arsitektur Efficientnet-B0 dan Resnet-50 untuk Klasifikasi Jenis Sa,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. October, pp. 1274–1286, 2025.
- [19] A. Angdressey, I. Y. Kairupan, and A. G. Mongkareng, “Web-Based Waste Detection Using YOLOv8 and Classification Performance Comparison: MobileNet and EfficientNet,” *Int. J. Image, Graph. Signal Process.*, vol. 17, no. 6, pp. 1–18, Dec. 2025, doi: 10.5815/ijigsp.2025.06.01.
- [20] L. Cunha, “Deep learning with Python (2^a ed) - François Chollet - Manning, outubro 2021, 504 pp.,” *Interações Soc. e as novas Mod.*, no. 42, pp. 113–115, Jun. 2022, doi: 10.31211/interacoes.n42.2022.r1.
- [21] Luntungan Stephen Pieters, “Development of Automatic Waste Classification System using CNN-Based Deep Learning to Support Smart Waste Management,” *INOVTEK Polbeng - Seri Inform.*, vol. 10, no. 1, pp. 214–224, Mar. 2025, doi: 10.35314/wst8mh87.
- [22] C. Shorten and T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 1, p. 60, Dec. 2019, doi: 10.1186/s40537-019-0197-0.
- [23] R. S. Samir, “EfficientNet Algorithm for Classification of Different Types of Cancer,” Jul. 2023, doi: 10.47852/bonviewAIA32021004.