

Klasifikasi Jenis Sampah Menggunakan Convolutional Neural Network untuk Mendukung Pengelolaan Limbah

Waste Type Classification Using Convolutional Neural Network for Supporting Waste Management

Laras Rahmawati¹, Sofi Defianti²

^{1,2} Universitas Singaperbangsa Karawang

³Program Studi Informatika, Fakultas ilmu komputer, Universitas Singaperbangsa Karawang

*e-mail: larasrahmawati53@gmail.com¹, sofi.defiyanti@unsika.ac.id²

Received:	Revised:	Accepted:	Available online:
20.12.2025	18.02.2026	17.03.2026	06.04.2026

Abstrak: Pengelolaan sampah merupakan salah satu permasalahan lingkungan yang dihadapi oleh banyak negara, termasuk Indonesia. Pemilahan sampah secara manual dinilai kurang efisien dan rentan terhadap kesalahan manusia. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi jenis sampah secara otomatis menggunakan metode Convolutional Neural Network (CNN). Dataset yang digunakan terdiri dari 10.704 gambar sampah yang terbagi dalam enam kelas, yaitu kaca, kardus, kertas, logam, plastik, dan residu. Model CNN dibangun dengan arsitektur tiga layer konvolusi dilengkapi teknik data augmentation untuk meningkatkan kemampuan generalisasi. Hasil eksperimen menunjukkan bahwa model mampu mencapai akurasi validasi sebesar 88,51% dengan nilai precision rata-rata 0,86 dan recall rata-rata 0,83. Kelas kaca memperoleh performa terbaik dengan F1-score 0,94, sedangkan kelas residu memperoleh F1-score terendah sebesar 0,69. Selain klasifikasi, sistem ini juga dilengkapi fitur rekomendasi daur ulang otomatis untuk setiap jenis sampah yang terdeteksi.

Kata kunci: Convolutional Neural Network, Klasifikasi Sampah, Deep Learning, Pengelolaan Limbah, Daur Ulang

Abstract: Waste management is one of the environmental problems faced by many countries, including Indonesia. Manual waste sorting is considered inefficient and prone to human error. This study aims to develop an automatic waste type classification system using the Convolutional Neural Network (CNN) method. The dataset used consists of 10,704 waste images divided into six classes: glass, cardboard, paper, metal, plastic, and residue. The CNN model was built with a three-convolutional-layer architecture equipped with data augmentation techniques to improve generalization. Experimental results show that the model achieved a validation accuracy of 88.51% with an average precision of 0.86 and average recall of 0.83. The glass class obtained the best performance with an F1-score of 0.94, while the residue class obtained the lowest F1-score of 0.69. In addition to classification, the system also features automatic recycling recommendations for each detected waste type.

Keywords: Convolutional Neural Network, Waste Classification, Deep Learning, Waste Management, Recycling

1. PENDAHULUAN

Permasalahan sampah telah menjadi isu global yang semakin mendesak untuk diselesaikan. Berdasarkan data dari Kementerian Lingkungan Hidup dan Kehutanan (KLHK), Indonesia menghasilkan sekitar 68,5 juta ton sampah per tahun dengan tingkat pengelolaan yang belum optimal [1]. Sebagian besar sampah yang dihasilkan masih dibuang ke Tempat Pembuangan Akhir (TPA) tanpa melalui proses pemilahan yang memadai, sehingga mengurangi potensi daur ulang dan meningkatkan dampak negatif terhadap lingkungan [2].

Pemilahan sampah merupakan langkah krusial dalam sistem pengelolaan limbah yang berkelanjutan. Dengan pemilahan yang tepat, sampah dapat diolah kembali menjadi produk yang bernilai ekonomis melalui proses daur ulang. Namun, pemilahan secara manual oleh manusia memiliki keterbatasan dalam hal kecepatan, konsistensi, dan akurasi, terutama ketika volume sampah sangat besar [2]. Kesalahan dalam pemilahan dapat menyebabkan kontaminasi material yang seharusnya dapat didaur ulang, sehingga menurunkan kualitas dan nilai ekonomisnya [3].

Perkembangan teknologi kecerdasan buatan (Artificial Intelligence), khususnya dalam bidang computer vision dan deep learning, membuka peluang baru dalam otomatisasi proses pemilahan sampah. Convolutional Neural Network (CNN) merupakan salah satu arsitektur deep learning yang telah terbukti efektif dalam tugas klasifikasi citra [4]. CNN mampu mengekstraksi

fitur-fitur visual secara hierarkis dari gambar tanpa memerlukan proses rekayasa fitur secara manual, sehingga sangat cocok diterapkan untuk pengenalan jenis sampah berdasarkan citra visual [5].

Beberapa penelitian terdahulu telah menunjukkan keberhasilan penerapan CNN dalam klasifikasi sampah. Sutanty dan Astuti [6], menerapkan arsitektur VGG16 untuk klasifikasi jenis sampah dengan dataset Garbage Classification dan memperoleh akurasi 87%. Penelitian serupa oleh Fathurrahman dan Akbar [7], merancang sistem identifikasi jenis sampah menggunakan TensorFlow Object Detection dan transfer learning. Namun, sebagian besar penelitian tersebut belum mengintegrasikan fitur rekomendasi pengelolaan sampah setelah proses klasifikasi dilakukan.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk: (1) mengembangkan model CNN untuk klasifikasi enam jenis sampah, yaitu kaca, kardus, kertas, logam, plastik, dan residu; (2) mengevaluasi performa model menggunakan metrik akurasi, precision, recall, dan F1-score; serta (3) mengintegrasikan fitur rekomendasi daur ulang otomatis berdasarkan hasil klasifikasi. Ruang lingkup penelitian ini mencakup pengembangan dan evaluasi model klasifikasi citra berbasis CNN menggunakan dataset Garbage Classification yang terdiri dari 10.704 gambar dengan enam kelas sampah. Penelitian ini tidak mencakup implementasi sistem pada perangkat keras fisik atau lingkungan produksi nyata, melainkan berfokus pada validasi performa model secara komputasional. Kontribusi utama penelitian ini adalah pengembangan sistem klasifikasi sampah berbasis CNN yang tidak hanya mengidentifikasi jenis sampah, tetapi juga memberikan informasi dan rekomendasi pengelolaan yang sesuai untuk setiap jenis sampah yang terdeteksi.

2. TINJAUAN PUSTAKA

2.1. *Pengelolaan Sampah*

Pengelolaan sampah merupakan serangkaian kegiatan yang mencakup pengumpulan, pengangkutan, pemrosesan, dan pembuangan limbah [8]. Undang-Undang Nomor 18 Tahun 2008 tentang Pengelolaan Sampah mengamanatkan bahwa pengelolaan sampah harus dilakukan secara sistematis, menyeluruh, dan berkesinambungan dengan memperhatikan aspek lingkungan. Pemilahan sampah berdasarkan jenisnya merupakan tahap awal yang penting dalam proses pengelolaan, karena menentukan metode pengolahan selanjutnya seperti daur ulang, komposting, atau pembuangan akhir.

2.2. *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) adalah arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data yang memiliki struktur grid, seperti gambar [4]. CNN terdiri dari beberapa jenis layer utama, yaitu convolutional layer yang berfungsi mengekstraksi fitur dari gambar menggunakan filter, pooling layer yang mengurangi dimensi spasial data untuk meningkatkan efisiensi komputasi, dan fully connected layer yang melakukan klasifikasi berdasarkan fitur yang telah diekstraksi [9]. Keunggulan CNN dibandingkan metode tradisional adalah kemampuannya untuk mempelajari representasi fitur secara otomatis dari data tanpa memerlukan proses feature engineering secara manual [10].

2.3. *Data Augmentation*

Data augmentation adalah teknik untuk meningkatkan ukuran dan keragaman dataset pelatihan dengan menerapkan transformasi pada gambar yang sudah ada [11]. Teknik yang umum digunakan meliputi rotasi, translasi, scaling, flipping, dan perubahan kontras. Pada penelitian ini, digunakan teknik shear transformation, random zoom, dan horizontal flip sebagai bentuk data augmentation untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko overfitting [10].


2.4. *Penelitian Terkait*

Beberapa penelitian terkait klasifikasi sampah menggunakan deep learning telah dilakukan oleh peneliti sebelumnya. Yang dan Thung [12], mengembangkan dataset TrashNet yang terdiri dari 2.527 gambar dalam enam kategori dan menggunakan CNN untuk klasifikasi. Bircanoğlu et al.

[13], membandingkan beberapa arsitektur deep learning seperti DenseNet dan InceptionV3 untuk klasifikasi sampah dengan akurasi terbaik mencapai 95%. Vo et al. [14], mengusulkan penggunaan transfer learning dengan model VGG-16 yang telah dilatih pada dataset ImageNet untuk klasifikasi limbah dan memperoleh akurasi 96%. Penelitian ini berbeda dengan penelitian sebelumnya karena selain melakukan klasifikasi, sistem juga dilengkapi dengan fitur rekomendasi daur ulang otomatis yang memberikan informasi praktis kepada pengguna mengenai cara pengelolaan sampah yang tepat.

3. METODE

Penelitian ini menggunakan pendekatan eksperimental kuantitatif dengan membangun model Convolutional Neural Network (CNN) untuk klasifikasi jenis sampah berdasarkan citra digital. Alur penelitian secara keseluruhan terdiri dari beberapa tahap utama, yaitu pengumpulan dataset, preprocessing dan augmentasi data, pembangunan arsitektur model CNN, pelatihan model, evaluasi performa, serta implementasi sistem prediksi dengan rekomendasi daur ulang. Diagram alur metodologi penelitian ditampilkan pada Gambar 1.



Gambar 1. Diagram Alur Metodologi Penelitian.

1.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset Garbage Classification yang diperoleh dari platform Kaggle (<https://www.kaggle.com/datasets/asdasdasdasdas/garbage-classification>). Dataset ini terdiri dari 10.704 gambar sampah yang terbagi dalam enam kelas, yaitu kaca, kardus, kertas, logam, plastik, dan residu. Dataset dibagi menjadi dua bagian, yaitu data training sebanyak 6.483 gambar (60,6%) dan data validasi sebanyak 4.221 gambar (39,4%). Pembagian dataset dilakukan secara acak menggunakan seed tetap (random seed = 42) untuk memastikan reproduksibilitas hasil eksperimen. Untuk meminimalkan risiko data leakage, dilakukan pemeriksaan visual dan penghapusan gambar duplikat atau hampir identik sebelum pembagian data dilakukan, sehingga tidak terdapat gambar yang sama atau sangat mirip yang tersebar di kedua subset. Perlu dicatat bahwa penelitian ini tidak menggunakan test set terpisah; akurasi 88,51% yang dilaporkan merupakan validation accuracy, sehingga klaim generalisasi terhadap data baru bersifat indikatif. Penggunaan test set terpisah atau k-fold cross-validation

direkomendasikan pada penelitian lanjutan untuk konfirmasi generalisasi yang lebih kuat. Distribusi data per kelas ditampilkan pada Tabel 1.

Tabel 1. Distribusi Dataset per Kelas

Kelas	Training	Validasi	Total
Kaca	579	579	1.158
Kardus	624	624	1.248
Kertas	1.807	1.807	3.614
Logam	1.210	759	1.969
Plastik	1.257	251	1.508
Residu	1.006	201	1.207
Total	6.483	4.221	10.704

1.2 Preprocessing dan Augmentasi Data

Tahap preprocessing dilakukan dengan mengubah ukuran seluruh gambar menjadi 150×150 piksel dan melakukan normalisasi nilai piksel ke rentang 0 hingga 1 dengan membagi setiap nilai piksel dengan 255. Sebelum augmentasi, dilakukan inspeksi kualitas gambar untuk mengidentifikasi dan menyaring gambar yang mengalami blur berlebih, noise tinggi, atau memiliki background clutter yang sangat dominan, sehingga hanya gambar dengan kualitas visual memadai yang digunakan dalam proses pelatihan. Untuk data training, diterapkan teknik data augmentation yang meliputi shear transformation dengan range 0,2, random zoom dengan range 0,2, dan horizontal flip secara acak. Teknik augmentasi ini bertujuan untuk meningkatkan variasi data training sehingga model lebih robust terhadap variasi posisi, ukuran, dan orientasi objek sampah dalam gambar. Untuk data validasi, hanya dilakukan normalisasi tanpa augmentasi agar evaluasi model lebih objektif.

1.3 Arsitektur Model CNN

Model CNN yang digunakan dalam penelitian ini terdiri dari tiga blok konvolusi yang masing-masing terdiri dari satu convolutional layer dan satu max pooling layer. Blok pertama menggunakan 32 filter berukuran 3×3 dengan fungsi aktivasi ReLU, diikuti max pooling berukuran 2×2. Blok kedua menggunakan 64 filter dengan konfigurasi yang sama. Blok ketiga menggunakan 128 filter. Setelah tiga blok konvolusi, output di-flatten menjadi vektor satu dimensi, kemudian dihubungkan ke fully connected layer dengan 128 neuron dan fungsi aktivasi ReLU. Dropout layer dengan rate 0,5 ditambahkan untuk mengurangi overfitting. Output layer menggunakan fungsi aktivasi softmax dengan enam neuron sesuai jumlah kelas. Detail arsitektur model ditampilkan pada Tabel 2.

Tabel 2. Arsitektur Model CNN

Layer	Output Shape	Parameter
Conv2D (32 filters, 3×3)	148×148×32	896
MaxPooling2D (2×2)	74×74×32	0
Conv2D (64 filters, 3×3)	72×72×64	18.496
MaxPooling2D (2×2)	36×36×64	0
Conv2D (128 filters, 3×3)	34×34×128	73.856
MaxPooling2D (2×2)	17×17×128	0
Flatten	36.992	0
Dense (128, ReLU)	128	4.735.104
Dropout (0.5)	128	0
Dense (6, Softmax)	6	774

1.4 Parameter Training

Model dikompilasi menggunakan optimizer Adam dengan learning rate 0,001 dan fungsi loss categorical crossentropy. Metrik evaluasi yang digunakan selama training adalah accuracy. Proses pelatihan dilakukan selama 20 epoch dengan batch size 32. Untuk memastikan reproduksibilitas, random seed ditetapkan pada nilai 42 pada seluruh komponen yang relevan (NumPy, TensorFlow, dan Python random). Seluruh proses training dan evaluasi diimplementasikan menggunakan bahasa pemrograman Python dengan library TensorFlow 2.x, Keras, NumPy, Matplotlib, dan Scikit-learn. Eksperimen dijalankan pada lingkungan Google

Colaboratory dengan akselerator GPU NVIDIA Tesla T4 (memori 15 GB). Total waktu pelatihan untuk 20 epoch adalah sekitar 18 menit.


1.5 Metrik Evaluasi

Evaluasi performa model dilakukan menggunakan beberapa metrik, yaitu accuracy, precision, recall, dan F1-score. Accuracy mengukur proporsi prediksi yang benar dari keseluruhan data. Precision mengukur proporsi prediksi positif yang benar dari seluruh prediksi positif. Recall mengukur proporsi data positif yang berhasil diidentifikasi dengan benar. F1-score merupakan rata-rata harmonik dari precision dan recall yang memberikan keseimbangan antara keduanya. Selain itu, confusion matrix digunakan untuk memvisualisasikan distribusi prediksi model terhadap setiap kelas.

4. HASIL DAN PEMBAHASAN

4.1 Hasil Training Model

Proses pelatihan model CNN dilakukan selama 20 epoch menggunakan dataset training yang telah melalui tahap preprocessing dan augmentasi. Grafik akurasi dan loss model selama proses training ditampilkan pada Gambar 2.



Gambar 2. Grafik Akurasi dan Loss Model per Epoch

Berdasarkan Gambar 2 dapat dilihat bahwa akurasi training meningkat secara konsisten dari 32,30% pada epoch pertama hingga mencapai 76,01% pada epoch ke-20. Akurasi validasi juga menunjukkan tren peningkatan yang positif, dimulai dari 56,24% pada epoch pertama dan mencapai 88,51% pada epoch terakhir. Nilai loss training menurun dari 1,65 menjadi 0,66, sedangkan loss validasi menurun dari 1,38 menjadi 0,36. Fakta bahwa akurasi validasi lebih tinggi dari akurasi training menunjukkan bahwa teknik data augmentation dan dropout berhasil mencegah overfitting, sehingga model memiliki kemampuan generalisasi yang baik terhadap data baru.

Tabel 3. Performa Model pada Epoch Terpilih

Epoch	Train Acc	Val Acc	Train Loss	Val Loss
1	32,30%	56,24%	1,6545	1,3799
5	53,94%	67,69%	1,2144	0,9395
10	63,95%	70,81%	0,9959	0,7448
15	70,00%	82,56%	0,8063	0,5044
20	76,01%	88,51%	0,6607	0,3596

4.2 Evaluasi Model

Setelah proses training selesai, model dievaluasi menggunakan data validasi. Tabel 4 menyajikan hasil evaluasi performa model untuk setiap kelas sampah.


Tabel 4. Classification Report Model CNN

Kelas	Precision	Recall	F1-Score	Support
Kaca	0,96	0,92	0,94	579

Kardus	0,91	0,81	0,86	624
Kertas	0,88	0,94	0,91	1.807
Logam	0,91	0,87	0,89	759
Plastik	0,82	0,75	0,78	251
Residu	0,68	0,71	0,69	201
Accuracy			0,89	4.221
Macro Avg	0,86	0,83	0,84	4.221
Weighted Avg	0,89	0,89	0,88	4.221

Berdasarkan Tabel 4, model CNN yang dikembangkan mencapai akurasi keseluruhan sebesar 88,51% pada data validasi. Kelas kaca memperoleh performa terbaik dengan precision 0,96, recall 0,92, dan F1-score 0,94. Hal ini menunjukkan bahwa model sangat baik dalam mengidentifikasi sampah kaca, kemungkinan karena karakteristik visual kaca yang cukup unik seperti transparansi dan pantulan cahaya yang membedakannya dari jenis sampah lainnya.

Kelas kertas memperoleh recall tertinggi sebesar 0,94, yang berarti model mampu mengidentifikasi 94% dari seluruh gambar kertas pada data validasi dengan benar. Namun, precision kelas kertas relatif lebih rendah (0,88), yang mengindikasikan adanya beberapa gambar dari kelas lain yang salah diklasifikasikan sebagai kertas. Hal ini dapat dipahami karena beberapa jenis sampah seperti kardus memiliki kemiripan tekstur dengan kertas.



Gambar 3. Confusion Matrix Model CNN


Gambar 3 menyajikan confusion matrix yang memvisualisasikan distribusi prediksi model. Dari confusion matrix terlihat bahwa kesalahan klasifikasi paling sering terjadi antara kelas kardus dan kertas, di mana 81 gambar kardus salah diklasifikasikan sebagai kertas. Hal ini disebabkan oleh kesamaan material dasar keduanya yang sama-sama berasal dari serat kayu. Selain itu, kelas logam juga memiliki 54 gambar yang salah diklasifikasikan sebagai kertas, yang mungkin disebabkan oleh kondisi pencahayaan atau sudut pengambilan gambar yang membuat tampilan logam menyerupai kertas.

4.3 Analisis Performa Per Kelas

Kelas plastik dan residu memperoleh performa yang relatif lebih rendah dibandingkan kelas lainnya. Kelas plastik mencapai F1-score 0,78 dengan precision 0,82 dan recall 0,75, sedangkan kelas residu memperoleh F1-score terendah sebesar 0,69 dengan precision 0,68 dan recall 0,71. Performa yang lebih rendah pada kedua kelas ini dapat disebabkan oleh beberapa faktor.

Pertama, jumlah data validasi untuk kelas plastik (251 gambar) dan residu (201 gambar) jauh lebih sedikit dibandingkan kelas lain seperti kertas (1.807 gambar) dan

logam (759 gambar). Ketidakseimbangan distribusi data ini (imbalanced dataset) dapat memengaruhi kemampuan model dalam mempelajari pola visual yang diskriminatif untuk kelas-kelas yang memiliki representasi data lebih sedikit [15]. Kedua, sampah residu umumnya memiliki bentuk dan tekstur yang sangat bervariasi karena dapat berupa campuran berbagai material, sehingga model kesulitan menemukan pola visual yang konsisten untuk kelas ini. Distribusi jumlah data per kelas secara visual ditampilkan pada Gambar 4. Ketidakseimbangan distribusi data ini juga tercermin pada nilai macro-F1 sebesar 0,84, yang lebih rendah dibandingkan weighted F1-score sebesar 0,88, mengindikasikan bahwa kelas-kelas minoritas seperti plastik dan residu belum mendapatkan representasi performa yang setara. Untuk meningkatkan performa pada kelas minoritas, beberapa strategi yang dapat diterapkan antara lain: (1) teknik oversampling seperti SMOTE pada level fitur atau augmentasi data yang lebih agresif khusus untuk kelas minoritas; (2) penggunaan class weight selama pelatihan untuk memberikan bobot lebih besar pada kelas yang memiliki jumlah sampel lebih sedikit; dan (3) penambahan data gambar aktual untuk kelas plastik dan residu agar keseimbangan distribusi antar kelas terpenuhi.



Gambar 4. Distribusi Dataset per Kelas

5. KESIMPULAN

Penelitian ini telah berhasil mengembangkan sistem klasifikasi jenis sampah menggunakan Convolutional Neural Network (CNN) yang mampu mengklasifikasikan enam jenis sampah, yaitu kaca, kardus, kertas, logam, plastik, dan residu. Model CNN yang dibangun dengan arsitektur tiga layer konvolusi dan dilengkapi teknik data augmentation mencapai akurasi validasi sebesar 88,51% dengan weighted F1-score 0,88. Kelas kaca memperoleh performa terbaik dengan F1-score 0,94, sedangkan kelas residu memperoleh performa terendah dengan F1-score 0,69. Selain fungsi klasifikasi, sistem juga dilengkapi fitur rekomendasi daur ulang otomatis yang memberikan informasi pengelolaan yang sesuai untuk setiap jenis sampah yang terdeteksi.

Untuk pengembangan lebih lanjut, beberapa saran yang dapat dilakukan antara lain: (1) menyeimbangkan distribusi dataset untuk setiap kelas agar model memiliki performa yang lebih merata; (2) menggunakan arsitektur CNN yang lebih kompleks seperti ResNet atau EfficientNet, atau menerapkan teknik transfer learning dengan model pre-trained untuk meningkatkan akurasi; (3) menambahkan jumlah kelas sampah untuk mencakup lebih banyak jenis limbah; dan (4) mengimplementasikan sistem ke dalam aplikasi mobile untuk deteksi sampah secara real-time.

DAFTAR PUSTAKA

- [1] L. J. Lingga, M. Yuana, N. A. Sari, H. Nur Syahida, and C. Sitorus, "Sampah di Indonesia: Tantangan dan Solusi Menuju Perubahan Positif," *Innov. J. Soc. Sci. Res.*, vol. 4, no. 4, pp. 12235–12247, 2024, doi: <https://doi.org/10.31004/innovative.v4i4.14542>.
- [2] E. Fitriahadi *et al.*, "Sosialisasi sampah organik dan anorganik menjadi eco enzym di dusun

- siyono Kulon Gunung Kidul,” *Has. Karya 'Aisyiyah untuk Indones.*, vol. 3, no. 2, pp. 106–114, 2024, doi: 10.31101/hayina.3383.
- [3] M. Muslihati, S. Sahibu, and I. Taufik, “Implementasi Algoritma Convolutional Neural Network untuk Klasifikasi Jenis Sampah Organik dan Non Organik,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 3, pp. 840–852, 2024, doi: 10.57152/malcom.v4i3.1346.
- [4] E. Oktayaessofa, C. A. Sari, E. H. Rachmawanto, and N. M. Yaacob, “Classification of Organic and Non-Organic Waste With Cnn-Mobilenet-V2,” *J. Tek. Inform.*, vol. 5, no. 4, pp. 1173–1180, Jul. 2024, doi: 10.52436/1.jutif.2024.5.4.2165.
- [5] S. R. Sausan Claudia and Y. P. Astuti, “Penerapan Algoritma Deep Learning CNN untuk Klasifikasi Pemilahan Sampah,” *JTERA (Jurnal Teknol. Rekayasa)*, vol. 8, no. 2, p. 183, 2024, doi: 10.31544/jtera.v8.i2.2023.183-190.
- [6] Ety Sutanty, Maukar, Dina Kusuma Astuti, and Handayani, “Penerapan Model Arsitektur VGG16 Untuk Klasifikasi Jenis Sampah,” *Decod. J. Pendidik. Teknol. Inf.*, vol. 3, no. 2, pp. 407–419, 2023, doi: 10.51454/decode.v3i2.331.
- [7] A. A. Fathurrahman and F. Akbar, “Perancangan Sistem Identifikasi Jenis Sampah Menggunakan Tensorflow Object Detection Dan Transfer Learning,” *J. Nas. Teknol. dan Sist. Inf.*, vol. 10, no. 1, pp. 64–71, 2024, doi: 10.25077/teknosi.v10i1.2024.64-71.
- [8] A. N. Sihananto, M. M. Al Haromainy, and A. P. Sari, “Pemilahan Jenis Sampah Menggunakan Algoritma Cnn,” *Scan J. Teknol. Inf. dan Komun.*, vol. 17, no. 3, Jan. 2023, doi: 10.33005/scan.v17i3.3523.
- [9] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00444-8.
- [10] C. Shorten and T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [11] R. Permana, H. Saldu, and D. I. Maulana, “Optimasi Image Classification Pada Jenis Sampah Dengan Data Augmentation Dan Convolutional Neural Network,” *J. Sist. Inf. dan Inform.*, vol. 5, no. 2, pp. 111–120, Aug. 2022, doi: 10.47080/simika.v5i2.1913.
- [12] G. Thung and M. Yang, “Classification of Trash for Recyclability Status,” *CS229 Proj. Rep., Stanford Univ.*, 2016.
- [13] Sunardi, A. Yudhana, and M. Fahmi, “Improving Waste Classification Using Convolutional Neural Networks: An Application of Machine Learning for Effective Environmental Management,” *Rev. d'Intelligence Artif.*, vol. 37, no. 4, pp. 845–855, 2023, doi: 10.18280/ria.370404.
- [14] 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, doi: 10.30871/jaic.v9i4.9958.
- [15] M. Malik *et al.*, “Waste Classification for Sustainable Development Using Image Recognition with Deep Learning Neural Network Models,” *Sustain.*, vol. 14, no. 12, pp. 1–18, 2022, doi: 10.3390/su14127222.