

Penerapan *Transfer Learning* Menggunakan Arsitektur *Deep CNN ResNet-50* untuk Klasifikasi Jenis Sampah

Adisaputra Marbun*, Budi Sudrajat, Hasta Herlan Asymar

Informatika, Universitas Bina Sarana Informatika, Jakarta

*marbunadi51@gmail.com

Abstrak— Pengelolaan sampah masih menjadi tantangan besar di Indonesia akibat tingginya timbulan sampah dan rendahnya tingkat daur ulang. Salah satu solusi inovatif yang dapat diterapkan adalah sistem klasifikasi sampah otomatis berbasis citra. Penelitian ini bertujuan membangun model klasifikasi jenis sampah menggunakan arsitektur *Deep Convolutional Neural Network ResNet-50* dengan pendekatan *transfer learning*. Dataset yang digunakan berasal dari Kaggle dan mencakup lima kelas: cardboard, glass, metal, paper, dan plastic. Data telah melalui tahap pra-pemrosesan, augmentasi, dan pembagian secara stratifikasi. Model dilatih selama 50 epoch menggunakan optimizor AdamW dan fungsi kehilangan CrossEntropyLoss. Hasil pelatihan menunjukkan akurasi validasi tertinggi sebesar 85%. Evaluasi dengan confusion matrix dan classification report menunjukkan model mampu melakukan klasifikasi secara akurat dan seimbang pada tiap kelas. Sistem ini juga dilengkapi antarmuka interaktif untuk prediksi gambar tunggal, memperlihatkan potensi penerapan nyata dalam pengelolaan sampah berbasis teknologi. Hasil penelitian membuktikan bahwa *transfer learning* dengan ResNet-50 efektif untuk klasifikasi citra sampah dan berpotensi mendukung solusi lingkungan berbasis kecerdasan buatan.

Kata Kunci— Citra; Jenis Sampah; Klasifikasi; Transfer Learning; ResNet-50.

DOI: 10.22441/jitkom.v10i1.009

Article History:

Received: Oct 6, 2025

Revised: Jan 20, 2026

Accepted: Jan 29, 2026

Published: Jan 31, 2026

I. PENDAHULUAN

Pengelolaan sampah merupakan salah satu tantangan serius yang dihadapi oleh berbagai negara, termasuk Indonesia. Berdasarkan laporan Kementerian Lingkungan Hidup dan Kehutanan (KLHK), Indonesia menghasilkan sekitar 69,9 juta ton sampah pada tahun 2023, namun data Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) hingga pertengahan 2024 baru mencatat 38,6 juta ton dari 365 kabupaten/kota. [1] Dari jumlah tersebut, hanya sekitar 11% yang berhasil didaur ulang, sementara sebagian besar masih berakhir di Tempat Pembuangan Akhir (TPA) atau mencemari lingkungan. [2] Rendahnya tingkat daur ulang disebabkan oleh kurangnya kesadaran masyarakat dalam memilah sampah serta terbatasnya sistem pengelolaan yang efektif. Kondisi ini menunjukkan adanya kesenjangan antara kebutuhan akan sistem pemilahan sampah yang efisien dengan kemampuan metode manual yang masih dominan digunakan.


Kondisi tersebut menimbulkan penelitian, yaitu kebutuhan akan sistem pemilahan sampah yang lebih cepat, akurat, dan efisien, tetapi hingga kini solusi teknologi yang teruji masih terbatas. Perkembangan teknologi Kecerdasan Buatan (*Artificial Intelligence/AI*), khususnya bidang computer vision, membuka peluang besar dalam menghadapi tantangan ini. Deep learning, dengan arsitektur *Convolutional Neural Network* (CNN), telah terbukti unggul dalam tugas klasifikasi citra karena kemampuannya mengekstrak fitur secara hierarkis. [3] Di antara berbagai arsitektur CNN, ResNet-50 muncul sebagai salah satu model yang menonjol. Dengan 50 lapisan dan mekanisme *skip connection*, ResNet-50 mampu mengatasi permasalahan *vanishing gradient* dan mencapai akurasi tinggi pada dataset yang kompleks. [4][5] Selain itu, konsep *transfer learning* semakin memperkuat keunggulan ResNet-50. Melalui

pemanfaatan model pra-latih (*pre-trained model*) yang telah dilatih pada dataset berskala besar seperti *ImageNet*, model dapat diadaptasi untuk klasifikasi citra spesifik seperti sampah, sehingga mengurangi kebutuhan data latih dalam jumlah besar sekaligus mempercepat proses pelatihan. [6] Dari sisi orisinalitas, penelitian ini menekankan pada penerapan ResNet-50 dengan *transfer learning* untuk kasus klasifikasi citra sampah di Indonesia, yang belum banyak dikaji secara komprehensif. [7] Hal ini diharapkan menjadi kontribusi baru dalam literatur, sekaligus memperkuat arah riset pemanfaatan AI untuk isu lingkungan berkelanjutan. [8][9]

Berdasarkan fenomena dan kajian tersebut, penelitian ini difokuskan untuk mengatasi permasalahan klasifikasi sampah anorganik melalui pemanfaatan arsitektur ResNet-50 dengan pendekatan *transfer learning*. Permasalahan yang dirumuskan dalam penelitian ini adalah bagaimana mengimplementasikan ResNet-50 dalam proses klasifikasi citra sampah serta bagaimana kinerjanya dalam membedakan kategori glass, metal, paper, cardboard, dan plastic. Penelitian ini bertujuan untuk membangun model klasifikasi yang efisien dan akurat serta menganalisis kinerjanya melalui metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*.

Orisinalitas penelitian ini terletak pada penerapan arsitektur ResNet-50 dalam konteks klasifikasi sampah anorganik di Indonesia, dengan memanfaatkan *transfer learning* untuk mengatasi keterbatasan dataset lokal. penelitian adalah teori deep learning dan computer vision, khususnya pada arsitektur CNN. Berdasarkan landasan tersebut, penelitian ini mengajukan hipotesis bahwa model ResNet-50 dengan pendekatan *transfer learning* mampu mengklasifikasikan citra jenis sampah dengan tingkat akurasi di atas 80%. Dengan demikian, penelitian ini tidak hanya berkontribusi pada pengembangan literatur

akademik mengenai klasifikasi citra berbasis deep learning, tetapi juga memberikan implikasi praktis dalam mendukung pengelolaan sampah berkelanjutan melalui penerapan teknologi berbasis kecerdasan buatan.



Gambar 1. Arsitektur ResNet-50

II. LITERATURE REVIEW

Penelitian ini dilakukan melalui studi pustaka dan penelusuran literatur, di mana penulis mencari berbagai referensi yang berkaitan dengan topik penelitian. Referensi tersebut dicari secara daring melalui internet. Studi Literatur yang ditemukan, seperti skripsi, jurnal, dan produk serupa, kemudian dianalisis untuk mendukung penelitian ini. Analisis tersebut bertujuan untuk memperluas cakupan terkait pada bidang penerapan *transfer learning* menggunakan arsitektur *Deep CNN* ResNet-50 untuk klasifikasi jenis sampah. Berikut adalah beberapa penelitian terkait dengan penelitian ini.

Penelitian sebelumnya menunjukkan keberhasilan penerapan *Convolution Neural Network* (CNN) dengan Arsitektur ResNet-50 dan fine-tuning. Penelitian yang dilakukan [4] berhasil mengklasifikasi kan jenis-jenis sampah dengan ResNet-50 menjadi base model yang didapatkan nilai akurasi sebesar 98,70% dengan rincian parameter batch size-16, epoch -18 learning rate 0.0001 dengan optimizer Adam. Penelitian [1] menggunakan Deep Learning berbasis CNN mampu mengklasifikasikan jenis-jenis sampah dalam tujuh kategori dengan akurasi model Model ResNeXt-101 89.62% dan fi Score nya 89,66%.

Selanjutnya [2] dengan model CNN yang di rancang dengan arsitektur ResNet-50 dengan Adam optimizer dan Learning rate 0,00005 untuk klasifikasi 10 jenis sampah anorganik yaitu (battery, biological,cardboard, clothes, glass, metal, paper, plastic, shoes, trash) memiliki akurasi yang lebih baik sebesar 97,73% sehingga mampu mendeteksi sampah anorganik dengan cukup baik. Sementara itu [3] membuktikan perbandingan ResNet-18 dan ResNet-50 untuk klasifikasi jenis pada sampah. Kemudian [10] membandingkan VGGNet-16 dan ResNet-50 dengan *transfer learning*.

III. METODOLOGI PENELITIAN

Penelitian ini bersifat eksperimental yang bertujuan untuk mengembangkan model klasifikasi citra jenis sampah menggunakan arsitektur deep learning ResNet50 dengan pendekatan *transfer learning*. Proses penelitian ini juga menggunakan metode eksperimen pada data citra sampah, dengan langkah-langkah sebagai berikut:

Pengumpulan Data

Tahapan awal adalah mengumpulkan dataset citra sampah dari sumber terbuka. Dataset yang digunakan adalah Trash Images dari platform Kaggle, yang terdiri dari lima kelas utama: cardboard, glass, metal, paper, dan plastic.

Pemisahaan Data

Setelah data terkumpul dan terstruktur, dilakukan pemisahan data menjadi dua subset, yaitu data pelatihan (training set) dan data pengujian (testing set). Pembagian dilakukan secara stratifikasi agar proporsi jumlah data pada tiap kelas tetap seimbang.

Desain

Tahapan ini mencakup perancangan sistem klasifikasi citra, termasuk pemetaan label numerik, pembuatan data pipeline, dan pra-pemrosesan citra. Data juga diproses dengan augmentasi seperti rotasi, zoom, dan flipping untuk meningkatkan variasi data dan mencegah overfitting.

Inisialisasi Model

Pada tahap ini dilakukan pemanggilan model ResNet-50 yang telah dilatih sebelumnya (pre-trained) pada dataset ImageNet. Layer awal dibekukan, sementara layer klasifikasi terakhir (fully connected) diubah agar sesuai dengan jumlah kelas dataset penelitian.

Pelatihan Model


Proses pelatihan dilakukan selama 50 epoch menggunakan optimizer AdamW dan fungsi kehilangan CrossEntropyLoss. Data dimuat melalui PyTorch Data Loader secara bertahap (batch) untuk efisiensi memori dan waktu pelatihan. Model dievaluasi setiap epoch untuk mencatat loss dan accuracy pada data pelatihan dan validasi.

Pengujian Model

Setelah pelatihan selesai, model diuji menggunakan data pengujian untuk mengukur performa sebenarnya. Evaluasi dilakukan dengan menghitung metrik seperti accuracy, precision, recall, f1-score dan Support pada masing-masing kelas, serta menampilkan confusion matrix untuk test data.

Eksprimen Model

Tujuan dari eksperimen dalam klasifikasi citra jenis sampah menggunakan arsitektur ResNet-50 adalah untuk mengevaluasi efektivitas pendekatan *transfer learning* dalam mengenali berbagai kategori sampah berdasarkan gambar.




Gambar 2. Alur Penelitian

IV. HASIL DAN ANALISA

Proses pelatihan dilakukan terhadap model klasifikasi citra jenis sampah menggunakan arsitektur ResNet-50 yang diimplementasikan melalui pendekatan *transfer learning*. Dataset dibagi ke dalam dua bagian, yaitu data latih sebanyak 1.673 gambar dan data uji sebanyak 717 gambar. Pembagian ini dilakukan secara stratifikasi untuk menjaga proporsi kelas tetap

seimbang pada kedua set data. Pembagian ini dilakukan secara stratifikasi untuk menjaga proporsi kelas tetap seimbang pada kedua set data. Distribusi kelas pada data latih menunjukkan bahwa kategori paper memiliki porsi terbesar sebesar 24,87%, diikuti oleh glass sebesar 20,98%, plastic sebesar 20,14%, metal sebesar 17,15%, dan cardboard sebesar 16,86%. Pola distribusi serupa juga diterapkan pada data uji dengan komposisi paper tetap dominan sebesar 24,83%. Keseimbangan distribusi ini penting karena mencegah model menjadi bias terhadap kelas mayoritas, sehingga setiap kategori memiliki peluang yang proporsional untuk dipelajari secara efektif.



Gambar 3. Data Train dan Data Test

Model dilatih selama beberapa *epoch* dengan menggunakan fungsi *loss* dan *optimizer* yang telah disesuaikan. Selama pelatihan, tren metrik evaluasi dicatat untuk memantau performa model, khususnya nilai *training loss*, *training accuracy*, *validation loss*, dan *validation accuracy*. Hasil yang diperoleh menunjukkan bahwa akurasi pelatihan meningkat secara konsisten seiring bertambahnya *epoch*, sementara nilai *validation loss* menurun secara stabil. Kondisi ini menandakan bahwa model mampu mempelajari data tanpa mengalami *overfitting* yang signifikan. Akurasi validasi tertinggi mencapai 85%, sehingga melampaui ambang batas performa minimum yang ditetapkan dalam penelitian ini, yaitu 80%. Dengan demikian, hipotesis alternatif (H1) terbukti, yaitu model ResNet-50 dengan pendekatan *transfer learning* mampu mengklasifikasikan jenis sampah dengan akurasi yang tinggi.


Tabel 1. *Accuracy*

Epoch	Train Loss	Train Accuracy	Test Loss	Test Accuracy
36	0.6570	0.7568	0.5226	0.8640
47	0.6195	0.7755	0.4541	0.8502
50	0.6011	0.7922	0.4776	0.8384

Proses pelatihan model klasifikasi citra dilakukan menggunakan fungsi *CrossEntropyLoss* sebagai acuan untuk mengukur kesalahan prediksi. Gambar IV menampilkan grafik perkembangan nilai *loss* dan akurasi selama 50 *epoch* pelatihan. Grafik *loss* menunjukkan tren penurunan baik pada data latih maupun data uji, yang menandakan model berhasil belajar dan mengurangi kesalahan prediksi seiring bertambahnya *epoch*. Menariknya, nilai *loss* pada data uji lebih rendah daripada pada data latih, sehingga dapat disimpulkan bahwa model tidak mengalami *overfitting* yang signifikan serta memiliki kemampuan generalisasi yang baik.

Pada sisi lain, grafik akurasi memperlihatkan peningkatan performa model dari *epoch* awal hingga akhir pelatihan. Akurasi


pada data uji mencapai sekitar 85%, sedikit lebih tinggi dibandingkan akurasi data latih. Hal ini menunjukkan bahwa model mampu melakukan klasifikasi dengan tingkat ketepatan yang cukup baik terhadap data baru yang belum pernah dilihat sebelumnya.



Gambar 4. *Epoch Accuracy*

Evaluasi lebih lanjut ditunjukkan melalui *confusion matrix*. Gambar 5 menunjukkan bahwa kelas metal dan paper memiliki akurasi tertinggi, masing-masing sebesar 93,50% dan 92,70%. Hal ini menandakan bahwa model cukup akurat dalam mengenali tekstur dan pola unik dari material logam maupun kertas. Sebaliknya, kelas plastic menjadi kategori dengan akurasi terendah, yaitu 67,59%. Kesalahan klasifikasi terutama terjadi ketika plastik salah dikenali sebagai glass atau metal.

Hal ini dapat disebabkan oleh kemiripan visual seperti bentuk botol dan sifat reflektif permukaannya.




Gambar 5. Confusion Matrix

Hasil classification report pada Gambar 6 hasilnya menunjukkan nilai pada *precision*, *recall*, dan *f1-score* bervariasi antar kelas. Kelas *cardboard* memiliki nilai *precision* tinggi (0.92) namun *recall* moderat (0.83), sedangkan kelas plastic memperlihatkan *recall* terendah (0.68), yang menunjukkan banyaknya kasus plastik yang salah klasifikasi. Secara keseluruhan, model memperoleh akurasi 85% dengan nilai rata-rata makro dan tertimbang yang seimbang pada kisaran 0.85–0.86, menandakan performa yang konsisten pada hampir semua kelas.

Classification Report Test				
	precision	recall	f1-score	support
cardboard	0.92	0.83	0.87	121
glass	0.84	0.89	0.86	150
metal	0.81	0.93	0.87	123
paper	0.85	0.93	0.89	178
plastic	0.87	0.68	0.76	145
accuracy			0.85	717
macro avg	0.86	0.85	0.85	717
weighted avg	0.86	0.85	0.85	717

Gambar 6. *Classification Report Test*

Selain evaluasi kuantitatif, uji prediksi tunggal juga dilakukan untuk memastikan kemampuan model dalam mengenali citra individual. Sebagaimana pada Gambar 7 model mampu berhasil mengklasifikasikan gambar kardus (*cardboard*) secara tepat. Keberhasilan ini menunjukkan bahwa model dapat mengenali fitur utama seperti warna coklat alami, tekstur bergelombang, dan tepi yang tidak beraturan. Temuan ini sejalan dengan metrik kuantitatif, di mana kelas *cardboard* memperoleh nilai f1-score sebesar 0.87.



Gambar 7. Prediksi Gambar Tunggal

Secara umum, hasil penelitian ini menunjukkan bahwa model berbasis deep learning yang dikembangkan memiliki kinerja yang cukup baik dalam mengklasifikasikan sampah ke dalam lima kategori utama. Meskipun demikian, tantangan masih ditemukan pada kelas *plastic*, sehingga penelitian selanjutnya perlu mengoptimalkan teknik *augmentation*, penggunaan arsitektur model yang lebih kompleks, atau penerapan metode *ensemble* untuk meningkatkan performa pada kelas dengan tingkat kesalahan klasifikasi tinggi.

V. KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan, dapat disimpulkan bahwa penelitian ini berhasil mengembangkan sistem klasifikasi citra jenis sampah berbasis deep learning dengan arsitektur *ResNet-50* melalui pendekatan *transfer learning*. Model dilatih menggunakan dataset *Trash Images* dari Kaggle yang telah diproses melalui tahap *prapemrosesan*, *augmentasi citra*, serta pembagian data secara *stratifikasi*. Hasil evaluasi menunjukkan bahwa model mampu mencapai akurasi validasi sebesar 85%, melampaui ambang batas minimal kinerja 80% yang ditetapkan dalam hipotesis. Nilai *precision*, *recall*, dan *f1-score* pada sebagian besar kelas menunjukkan performa yang baik dan seimbang, sehingga hipotesis alternatif (H_1) dapat diterima bahwa arsitektur *ResNet-50* mampu

memberikan hasil klasifikasi yang akurat sesuai standar penelitian. Selain itu, analisis *confusion matrix* dan *classification report* memperlihatkan bahwa model dapat mengklasifikasikan sebagian besar kelas dengan konsisten dan stabil, meskipun masih terdapat tantangan dalam membedakan kelas *plastic* dengan material lain yang memiliki kemiripan visual. Sistem yang dikembangkan juga telah berhasil diimplementasikan dengan fitur prediksi gambar tunggal melalui antarmuka interaktif, yang memungkinkan pengguna menguji model secara langsung pada citra baru di luar data pelatihan. Secara keseluruhan, arsitektur *ResNet-50* terbukti efektif untuk klasifikasi citra sampah dan berpotensi mendukung sistem pengelolaan sampah berbasis teknologi.

DAFTAR PUSTAKA

- [1] H. Ahmed Khan, S. S. Naqvi, A. A. K. Alharbi, S. Alotaibi, and M. Alkhatami, "Enhancing trash classification in smart cities using federated deep learning," *Scientific Reports*, vol. 14, no. 1, May 2024, doi: 10.1038/s41598-024-62003-4.
- [2] A. Bustamin, B. Zaman, and F. K. Hakim, "Sistem Multi Klasifikasi Sampah Anorganik Dengan Menggunakan Transfer Learning," *Jurnal INSIPRO (Information System and Processing)*, vol. 8, no. 2, 2023, doi: 10.24252/insipro.v8i2.42385.
- [3] C. E. Nainggolan, M. Nasir, Fatoni, and D. Udariansyah, "Perbandingan Klasifikasi Jenis Sampah Menggunakan Convolutional Neural Network Dengan Arsitektur *ResNet18* dan *ResNet50*," *CSRID (Computer Science Research and Its Development Journal)*, vol. 16, no. 1, pp. 76–90, Mar. 2024, doi: 10.22303/csrid-16.1.2024.76-90.
- [4] J. N. Nuariputri, M. Maimunah, and P. S. Sukmasetya, "Klasifikasi Jenis Sampah Menggunakan Base *ResNet-50*," *jistik*, vol. 22, no. 3, pp. 379–386, Oct. 2023, doi: 10.32409/jistik.22.3.3380.
- [5] L. Li, R. Wang, M. Zou, F. Guo, and Y. Ren, "Enhanced *ResNet-50* for garbage classification: Feature fusion and depth-separable convolutions," *PLOS ONE*, vol. 20, no. 1, p. e0317999, 2025, doi: 10.1371/journal.pone.0317999.
- [6] L. Z. Nurmia, A. Andriyatno, F. Fitriani, and R. Munandar, "Meningkatkan Hasil Belajar Matematika Siswa Menggunakan Media Interaktif Powtoon Kelas V SDN 30 Ampenan," *Lambda: Jurnal Ilmiah Pendidikan MIPA dan Aplikasinya*, vol. 5, no. 1, pp. 1–8, Feb. 2025, doi: 10.58218/lambda.v5i1.1104.
- [7] W. Muhammad Ardana and Kusri Kusri, "Optimasi Algoritma Convolutional Neural Network dengan Arsitektur *Efficientnet-B0* dan *Resnet-50* untuk Klasifikasi Jenis Sampah: Optimization of Convolutional Neural Network Algorithm with *Efficientnet-B0* and *Resnet-50* Architecture for Waste Type Classification," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 4, pp. 1274–1286, 2025, doi: 10.57152/malcom.v5i4.2030.
- [8] X. Ma, Z. Li, and Z. Lei, "An Improved *ResNet-50* for Garbage Image Classification," *Tehnički vjesnik*, vol. 29, no. 5, pp. 1552–1559, Oct. 2022, doi: 10.17559/TV-20220420124810.
- [9] S. Kundu, M. Sharma, and A. S. Pillai, "AI-Powered Trash Classification System for Lakes and Water Bodies Using Transfer Learning," *2024 Third International Conference on Power, Control and Computing Technologies (ICPC2T)*, pp. 163–167, Jan. 2024, doi: 10.1109/icpc2t60072.2024.10474611.
- [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," *Frontiers in Environmental Science*, vol. 10, Oct. 2022, doi: 10.3389/fenvs.2022.1043843.