

PENINGKATAN AKURASI KLASIFIKASI CITRA SAMPAH MENGGUNAKAN AUGMENTASI DATA ADAPTIF BERBASIS GAYA VISUAL

Fathurrahman Al-Falah¹, Martanto², Yudhistira Arie Wijaya³, Riri Narasati⁴.

Program Studi Teknik Informatika¹⁴
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
cintafathurrahman@gmail.com

(*) Corresponding Author : cintafathurrahman@gmail.com
Published : 30 Juni 2026

Abstract—Waste image classification remains challenged by class imbalance and illumination variability, both of which introduce domain shift and significantly reduce the performance of Convolutional Neural Network (CNN) models. This study aims to improve classification accuracy and model generalization by implementing an adaptive style-based data augmentation strategy informed by exploratory data analysis (EDA). The proposed method designs class-specific augmentation policies using controlled photometric transformations—brightness, contrast, saturation, and gamma—combined with adaptive oversampling to rebalance the dataset. Experiments were conducted using the Kaggle “Trash Type Image Dataset,” which initially exhibited substantial imbalance across six classes (paper 594, glass 501, plastic 482, metal 410, cardboard 403, trash 137). After applying adaptive augmentation, the dataset was balanced to 3,564 images (594 per class). A lightweight transfer-learning CNN model was trained using an 80:20 stratified split with weighted loss. Evaluation included accuracy, precision, recall, F1-score, as well as image fidelity metrics (SSIM, PSNR, FID) to ensure the augmented images preserved semantic integrity. The results demonstrate that adaptive style-based augmentation effectively expands illumination diversity, mitigates class imbalance, and enhances model robustness. The augmented dataset achieved a validation accuracy of 0.687 and improved average recall/F1 by 7–10% compared to the non-augmented baseline. These findings highlight the effectiveness of adaptively designed style-based augmentation in improving waste image classification performance under diverse lighting and domain conditions.

Keywords: adaptive style-based augmentation; waste image classification; data balancing; photometric augmentation; Convolutional Neural Network

Abstrak—Klasifikasi citra sampah masih menghadapi tantangan utama berupa ketidakseimbangan jumlah sampel dan variasi pencahayaan yang menyebabkan domain shift sehingga menurunkan performa model berbasis Convolutional Neural Network (CNN). Penelitian ini bertujuan meningkatkan akurasi dan generalisasi model melalui penerapan augmentasi data adaptif berbasis gaya visual (style-based augmentation) yang dirancang menggunakan analisis eksploratori data (EDA). Metode yang diusulkan mengembangkan kebijakan augmentasi per-kelas menggunakan transformasi fotometrik terkontrol—brightness, contrast, saturation, dan gamma—serta strategi oversampling adaptif untuk menyeimbangkan distribusi data. Eksperimen dilakukan pada dataset “Trash Type Image Dataset” dari Kaggle, yang awalnya tidak seimbang (paper 594, glass 501, plastic 482, metal 410, cardboard 403, trash 137). Setelah augmentasi adaptif, jumlah sampel diseimbangkan menjadi 3.564 citra (594 per kelas). Model CNN ringan dengan transfer learning dilatih menggunakan stratified split 80:20 dan weighted loss. Evaluasi dilakukan menggunakan akurasi, precision, recall, F1-score, serta metrik fidelity citra (SSIM, PSNR, FID) untuk memastikan tidak terjadi semantic drift. Hasil menunjukkan bahwa augmentasi adaptif berbasis gaya visual secara konsisten memperluas distribusi pencahayaan, mengurangi ketidakseimbangan kelas, dan meningkatkan robustnes model. Model menghasilkan akurasi validasi 0,687, dengan peningkatan recall/F1 sebesar 7–10% dibandingkan baseline tanpa augmentasi. Temuan ini menegaskan bahwa augmentasi berbasis gaya visual yang dirancang secara adaptif merupakan pendekatan efektif untuk meningkatkan kinerja klasifikasi citra sampah pada lingkungan dengan variasi pencahayaan dan domain yang beragam.

Kata kunci: augmentasi data adaptif berbasis gaya visual; klasifikasi citra sampah; data balancing; photometric augmentation; Convolutional Neural Network

INTRODUCTION

Klasifikasi citra sampah berbasis deep learning menghadapi beberapa tantangan utama yang membatasi performa dan generalisasi model. Pertama, banyak dataset sampah tersedia berskala kecil dan bersifat tidak seimbang antarkelas—misalnya dominasi kelas seperti kertas dibandingkan sampah umum—sehingga model cenderung bias terhadap kelas mayoritas [1], [2]. Kedua, citra sampah di dunia nyata sering berisi beberapa objek, latar yang berantakan, dan kondisi pengambilan yang berbeda-beda sehingga menciptakan domain shift antara data pelatihan dan kondisi penerapan [3].


Variasi pencahayaan merupakan faktor yang khususnya krusial: perubahan kecerahan, bayangan, dan paparan cahaya dapat mengubah distribusi fitur visual secara signifikan dan menurunkan akurasi model. Penelitian empiris melaporkan penurunan performa pada kondisi pencahayaan yang berbeda dan merekomendasikan augmentasi fotometrik adaptif atau teknik simulasi pencahayaan saat pelatihan [4], [5], [6]. Selain itu, kebutuhan implementasi pada perangkat edge mendorong penggunaan arsitektur ringan dan strategi efisiensi model agar solusi dapat berjalan real-time di lingkungan lapangan [7], [8].

Literatur terkini menekankan solusi berorientasi data (data-centric), seperti augmentasi generatif, style-based augmentation, dan cross-domain sampling, yang dapat memperkaya variasi penampakan kelas minoritas dan mengurangi domain shift. Namun, sebagian besar studi masih menerapkan kebijakan augmentasi generik tanpa menyesuaikan intensitas atau jenis augmentasi berdasarkan karakteristik dataset yang terungkap melalui exploratory data analysis (EDA) [1], [9].

Berdasarkan pemetaan masalah di atas, terlihat celah penelitian yang jelas: belum banyak studi yang menggabungkan augmentasi berbasis gaya (style-based) yang adaptif terhadap temuan EDA—terutama untuk mengatasi variasi pencahayaan sekaligus ketidakseimbangan kelas pada dataset citra sampah. Celah ini mengilhami pendekatan penelitian yang data-driven dan berfokus pada augmentasi adaptif yang terkalibrasi menurut distribusi pencahayaan dan frekuensi kelas.

MATERIALS AND METHODS

Penelitian ini dilaksanakan melalui beberapa tahapan yang disusun secara sistematis untuk mencapai tujuan penelitian, yaitu meningkatkan akurasi klasifikasi citra limbah melalui penerapan augmentasi data adaptif berbasis gaya visual. Setiap tahapan dirancang agar saling berkaitan dan membentuk alur penelitian yang terstruktur.



Gambar 1. Alur Penelitian.

penelitian diawali dengan tahap pengumpulan dan persiapan dataset, di mana data citra limbah dikumpulkan dari sumber yang relevan, kemudian dilakukan proses seleksi dan pra-proses untuk memastikan kualitas serta konsistensi data yang akan digunakan. Tahap berikutnya adalah analisis eksploratori data (Exploratory Data Analysis/EDA) yang bertujuan untuk memahami karakteristik dataset melalui analisis distribusi kelas, variasi citra, serta potensi ketidakseimbangan data.

Selanjutnya dilakukan perancangan augmentasi adaptif berbasis gaya visual, di mana teknik augmentasi dikembangkan dengan menyesuaikan karakteristik visual dataset agar mampu memperkaya keragaman data tanpa mengubah makna semantik citra. Tahapan berikutnya yaitu penerapan dan validasi augmentasi, yang dilakukan untuk menguji efektivitas metode augmentasi yang telah dirancang terhadap kualitas serta keragaman citra hasil augmentasi.

Tahapan terakhir adalah pelatihan dan evaluasi model, di mana model klasifikasi citra dilatih menggunakan dataset yang telah diaugmentasi, kemudian dievaluasi menggunakan metrik kinerja tertentu untuk menilai peningkatan akurasi yang dihasilkan. Hasil dari tahap ini menjadi dasar dalam menilai keberhasilan penerapan augmentasi adaptif dalam konteks peningkatan performa model klasifikasi citra limbah.


RESULTS AND DISCUSSION

Penerapan skema augmentasi adaptif yang telah dirancang pada subbab sebelumnya menghasilkan perubahan signifikan baik dari sisi kuantitatif maupun distribusi karakteristik fotometrik dataset. Secara kuantitatif, augmentasi difokuskan untuk menyeimbangkan jumlah sampel antar kelas,

sedangkan secara kualitatif dan distribusional, augmentasi ditujukan untuk memperluas variasi kecerahan sehingga kelas-kelas yang semula memiliki rentang intensitas sempit atau *bias* terhadap kondisi pencahayaan tertentu menjadi lebih beragam dan representatif. Subbab ini menguraikan hasil penerapan augmentasi, analisis distribusi kecerahan setelah augmentasi, serta langkah-langkah yang ditempuh untuk meminimalkan risiko *data leakage* antara himpunan pelatihan dan validasi.

Dari sisi kuantitatif, augmentasi adaptif berhasil menyamakan jumlah sampel untuk setiap kelas. Sebagaimana telah dijelaskan pada Tabel 1, seluruh kelas pada dataset akhir memiliki jumlah sampel sekitar 594 citra per kelas. Dengan demikian, total dataset setelah augmentasi menjadi sekitar 3.564 citra yang terdistribusi secara seimbang di antara enam kelas: *cardboard*, *glass*, *metal*, *paper*, *plastic*, dan *trash*. Setelah dataset diseimbangkan, dilakukan pembagian data menjadi himpunan pelatihan dan validasi menggunakan skema *stratified split* dengan rasio sekitar 80:20. Prosedur ini menghasilkan sekitar 2.851 citra pada himpunan pelatihan dan 713 citra pada himpunan validasi, di mana setiap kelas tetap terwakili secara proporsional pada kedua subset tersebut.

Untuk menilai dampak augmentasi terhadap distribusi kecerahan, dilakukan analisis perbandingan histogram brightness sebelum dan sesudah augmentasi gaya. Fokus analisis diarahkan pada kanal V (Value) dalam ruang warna HSV, yang merepresentasikan intensitas kecerahan piksel. Perbandingan ini divisualisasikan dalam bentuk plot kepadatan (density) pada Gambar 4.6, di mana histogram kecerahan untuk citra asli dan beberapa varian gaya hasil augmentasi digambarkan secara tumpang tindih.



E
Gambar 1 Histogram sebelum vs sesudah augmentasi

Berdasarkan Gambar 2 dapat diamati bahwa distribusi kecerahan piksel pada citra asli (ditunjukkan oleh kurva berwarna biru) terkonsentrasi pada rentang intensitas yang relatif sempit, dengan puncak distribusi yang

berada pada kisaran nilai kecerahan tinggi (sekitar 220–240). Konsentrasi ini mengindikasikan bahwa sebelum augmentasi, sebagian besar piksel berada pada kondisi pencahayaan terang yang cukup seragam. Setelah augmentasi gaya diterapkan, kurva distribusi untuk varian gaya pertama dan kedua (misalnya ditunjukkan oleh warna merah dan oranye) memperlihatkan pergeseran dan pelebaran sebaran kecerahan. Pada salah satu varian, puncak distribusi bergeser ke arah intensitas yang sedikit lebih rendah, yang menunjukkan simulasi kondisi pencahayaan yang lebih redup; sementara pada varian lain, puncak distribusi menjadi lebih tajam di sekitar nilai intensitas tinggi, yang mensimulasikan kondisi pencahayaan sangat terang.

Secara lebih rinci, peningkatan lebar sebaran (spread) distribusi pada kurva varian gaya menunjukkan bahwa augmentasi telah menambahkan piksel dengan rentang kecerahan yang lebih luas, baik di sisi intensitas menengah maupun di sekitar ambang kecerahan maksimal. Hal ini berarti bahwa model tidak lagi hanya terekspos pada satu pola pencahayaan yang dominan, tetapi juga pada variasi pencahayaan yang lebih heterogen. Di sisi lain, bentuk kurva yang tetap halus dan tidak menunjukkan puncak-puncak tajam yang tidak wajar mengindikasikan bahwa transformasi fotometrik yang diterapkan masih berada pada rentang yang realistis dan tidak menghasilkan artefak ekstrem yang dapat mengganggu proses pembelajaran. Dengan demikian, Gambar 2 memberikan bukti bahwa augmentasi gaya berhasil memperluas dan menyeimbangkan distribusi kecerahan tanpa mengorbankan kealamian citra.

Untuk melengkapi analisis distribusi kecerahan tersebut, ringkasan perubahan jumlah sampel per kelas sebelum dan sesudah augmentasi disajikan pada Tabel 1. Tabel ini digunakan untuk menunjukkan secara eksplisit bagaimana proses augmentasi adaptif tidak hanya mengubah karakteristik fotometrik, tetapi juga menyeimbangkan ukuran setiap kelas sehingga kontribusi masing-masing kelas terhadap proses pelatihan menjadi lebih proporsional.

Tabel 1 Jumlah sampel per kelas sebelum dan sesudah augmentasi

Class	Jumlah Awal	Jumlah Akhir
paper	594	594
glass	501	594
plastic	482	594
metal	410	594

cardboard	403	594
trash	137	594

Berdasarkan Tabel 1 dapat diamati bahwa sebelum augmentasi, distribusi jumlah sampel antar kelas bersifat tidak seimbang. Kelas *paper* sejak awal telah memiliki 594 sampel, sedangkan kelas *glass*, *plastic*, *metal*, dan *cardboard* masing-masing hanya memiliki 501, 482, 410, dan 403 sampel. Ketimpangan paling ekstrem terjadi pada kelas *trash* yang hanya berjumlah 137 sampel, jauh di bawah kelas lainnya. Setelah proses augmentasi adaptif diterapkan, seluruh kelas disamakan jumlahnya menjadi 594 sampel sehingga tidak ada penambahan sampel untuk kelas *paper*, sementara kelas *glass*, *plastic*, *metal*, *cardboard*, dan *trash* masing-masing memperoleh tambahan 93, 112, 184, 191, dan 457 sampel sintesis.

Untuk menegaskan implikasi penting dari perubahan tersebut, beberapa poin utama dapat dirangkum sebagai berikut:

Penyeimbangan kelas secara eksplisit. Augmentasi adaptif diarahkan untuk menghapus ketimpangan antara kelas mayoritas dan minoritas dengan cara menargetkan jumlah akhir yang sama, yaitu 594 sampel per kelas. Dengan demikian, setiap kelas memberikan kontribusi yang relatif setara terhadap fungsi *loss* selama pelatihan.

Penguatan representasi kelas minoritas. Penambahan sampel sintesis yang paling besar terjadi pada kelas *trash* dan *cardboard*. Hal ini penting untuk memperkecil kesenjangan statistik terhadap kelas mayoritas sehingga model memiliki peluang lebih besar untuk mempelajari pola visual khas dari kelas yang sebelumnya sangat kurang terwakili.

Pengendalian pertumbuhan data yang terukur. Penambahan sampel pada kelas *glass*, *plastic*, dan *metal* dilakukan secara moderat, sehingga distribusi menjadi rata tanpa menyebabkan dominasi baru ataupun pertumbuhan data yang berlebihan. Strategi ini menjaga keseimbangan antara kebutuhan variasi data dan biaya komputasi.

Secara keseluruhan, Tabel 1 menegaskan bahwa augmentasi adaptif yang diterapkan tidak hanya memperbanyak data secara acak, tetapi dirancang untuk mencapai penyeimbangan distribusi kelas yang sistematis. Kondisi ini mempersiapkan lingkungan pelatihan yang lebih adil bagi optimasi parameter model dan diharapkan berkontribusi

pada peningkatan kemampuan generalisasi pada tahap pemodelan klasifikasi berikutnya.

Dari sudut pandang metodologis, penerapan augmentasi ini juga diiringi dengan mekanisme pengendalian *data leakage* antara himpunan pelatihan dan validasi. Risiko *data leakage* muncul apabila varian augmentasi dari citra yang sama tersebar pada kedua subset tersebut, sehingga model dapat memperoleh keuntungan tidak wajar saat evaluasi. Untuk mencegah hal ini, pemisahan data dilakukan dengan menggunakan identitas unik (*image_id*) yang melekat pada setiap citra asli. Prosedur yang diterapkan adalah sebagai berikut:

seluruh citra asli terlebih dahulu diberi *image_id* unik.

pemisahan *image_id* ke dalam himpunan pelatihan dan validasi dilakukan satu kali menggunakan skema *stratified split*.

seluruh varian augmentasi yang dihasilkan dari suatu *image_id* dialokasikan ke subset yang sama dengan citra aslinya. Dengan prosedur ini dipastikan bahwa tidak ada satu pun *image_id* yang muncul sekaligus pada himpunan pelatihan dan validasi.

Pemeriksaan tambahan terhadap daftar *image_id* pada kedua subset dilakukan untuk memverifikasi bahwa pemisahan benar-benar bebas dari duplikasi. Hasil pemeriksaan menunjukkan bahwa himpunan pelatihan dan validasi memiliki himpunan *image_id* yang saling eksklusif, sehingga dapat disimpulkan bahwa *data leakage* tidak terjadi. Log dan potongan kode yang digunakan untuk verifikasi pemisahan ini disertakan pada Lampiran sebagai bukti pendukung. Dengan demikian, dapat dinyatakan bahwa penerapan augmentasi adaptif pada penelitian ini tidak hanya memperbaiki distribusi data dari sisi kuantitatif dan fotometrik, tetapi juga dilaksanakan dengan prosedur validasi yang ketat agar evaluasi kinerja model pada himpunan validasi tetap mencerminkan kemampuan generalisasi yang sesungguhnya.

Pelatihan dan Evaluasi Model

Evaluasi akhir dari penelitian ini dilakukan untuk mengetahui seberapa baik model klasifikasi citra sampah bekerja setelah diterapkannya strategi augmentasi data adaptif berbasis gaya. Penilaian ini melibatkan berbagai metrik evaluasi model, visualisasi embedding, serta analisis kurva pembelajaran dan fidelity dari data hasil augmentasi.

Evaluasi Metrik Per Kelas

Model klasifikasi citra sampah yang dikembangkan dalam penelitian ini telah dilatih menggunakan pendekatan augmentasi data adaptif berbasis gaya. Setelah proses pelatihan selesai, dilakukan evaluasi komprehensif terhadap

performa model dengan menggunakan metrik klasifikasi standar. Evaluasi ini bertujuan untuk mengukur sejauh mana model mampu membedakan antar kelas, terutama pada kelas minoritas yang jumlah datanya lebih sedikit. Hasil metrik evaluasi tersebut disajikan dalam bentuk tabel sebagaimana terlihat pada Tabel 2 berikut ini:

Tabel 2 Metrik Evaluasi Per Kelas

	precisi on	recall	f1- score	support
cardboard	0.7692	0.8475	0.8065	118
glass	0.6842	0.5462	0.6075	119
metal	0.5964	0.8319	0.6947	119
paper	0.7788	0.6807	0.7265	119
plastic	0.7089	0.4706	0.5657	119
trash	0.7626	0.8908	0.8217	119
accuracy	0.7111	0.7111	0.7111	0
macro avg	0.7167	0.7113	0.7037	713
weighted avg	0.7166	0.7111	0.7036	713

Berdasarkan Tabel 2, dapat diamati bahwa nilai akurasi keseluruhan model sebesar 71,11%. Namun demikian, pemahaman performa model menjadi lebih informatif apabila dilihat melalui metrik per kelas, sehingga tidak hanya bergantung pada akurasi global.

Secara ringkas, temuan-temuan penting yang diperoleh dari Tabel 2 dapat dirumuskan sebagai berikut:

Kelas *trash* memiliki nilai f1-score tertinggi sebesar 0.8217 dan recall 0.8908. Fakta ini menunjukkan bahwa kelas yang semula merupakan kelas dengan jumlah sampel paling sedikit justru dapat dikenali dengan sangat baik setelah diterapkan strategi augmentasi adaptif berbasis gaya, sehingga permasalahan kelas minoritas berhasil diminimalkan.

Kelas *cardboard* juga menunjukkan performa yang tinggi dengan f1-score sebesar 0.8065 dan recall 0.8475. Kondisi ini mengindikasikan bahwa sebagian besar citra pada kelas tersebut diklasifikasikan dengan benar oleh model, dan hanya sebagian kecil yang mengalami kesalahan prediksi.

Kelas *metal* memiliki f1-score sebesar 0.6947 dengan recall yang tinggi (0.8319) namun precision relatif lebih rendah (0.5964). Hal ini mengisyaratkan bahwa model cenderung sensitif dalam mendeteksi kelas *metal*, tetapi masih terdapat sejumlah prediksi positif yang keliru sehingga mengurangi nilai precision.

Kelas *glass* dan *plastic* menunjukkan performa relatif terendah, dengan f1-score masing-masing sebesar 0.6075 dan 0.5657 serta recall yang lebih rendah dibanding kelas lain (0.5462 dan 0.4706). Kondisi ini mengindikasikan adanya kemiripan fitur visual dengan kelas lain, misalnya kemiripan tekstur dan warna dengan kelas *paper* atau *metal*, sehingga masih sering terjadi mis-klasifikasi.

Nilai *macro average* f1-score tercatat sebesar 0.7037, sedangkan *weighted average* f1-score sebesar 0.7036. Kedua nilai ini saling berdekatan, yang menandakan bahwa performa model relatif seimbang jika dilihat dari rata-rata antar kelas maupun dengan mempertimbangkan proporsi jumlah sampel setiap kelas.

Secara keseluruhan, hasil tersebut menunjukkan bahwa proses pelatihan yang dikombinasikan dengan augmentasi adaptif berbasis gaya tidak hanya mampu meningkatkan akurasi global, tetapi juga berkontribusi terhadap perbaikan performa pada kelas-kelas minoritas. Meskipun demikian, masih terdapat ruang perbaikan khususnya pada kelas *glass* dan *plastic* yang memerlukan strategi tambahan, misalnya penajaman augmentasi domain-spesifik atau penyesuaian arsitektur model untuk menangkap perbedaan fitur yang lebih halus antar kelas yang serupa secara visual.

CONCLUSION

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan augmentasi data adaptif berbasis gaya visual mampu meningkatkan performa model klasifikasi citra sampah. Model yang dilatih pada dataset hasil augmentasi mencapai akurasi validasi sebesar 68,7% dan rata-rata peningkatan F1-score sebesar 7-10% dibanding baseline. Peningkatan terjadi terutama pada kelas minoritas seperti "trash" yang sebelumnya underperforming. Proses augmentasi berhasil menyeimbangkan distribusi kelas dan memperluas variasi pencahayaan, sebagaimana terlihat dari histogram warna dan evaluasi visual.

Namun demikian, keterbatasan utama penelitian ini mencakup potensi overfitting akibat kompleksitas augmentasi serta evaluasi yang hanya dilakukan pada satu dataset internal. Evaluasi terhadap domain luar atau dataset eksternal belum dilakukan, sehingga generalisasi model belum dapat dinyatakan menyeluruh. Aspek lain yang juga

menjadi perhatian adalah keterbatasan dalam uji implementasi pada perangkat edge dengan sumber daya terbatas.

Kode program dan konfigurasi pelatihan yang digunakan dalam penelitian ini akan dipublikasikan di repositori GitHub publik setelah proses validasi internal. Dataset yang digunakan merupakan dataset open-access (Trash Type Image Dataset - Kaggle) dengan lisensi publik. Penelitian ini tidak melibatkan data pribadi atau informasi sensitif, sehingga tidak memiliki isu etika terkait penggunaan data.

REFERENCE

- [1] H. Abdu and M. H. Mohd Noor, "A survey on waste detection and classification using deep learning," *IEEE Access*, vol. 10, pp. 128151–128165, 2022, doi: 10.1109/ACCESS.2022.3226682.
- [2] J. Fan, L. Cui, and S. Fei, "Waste detection system based on data augmentation and YOLO_EC," *Sensors*, vol. 23, no. 7, p. 3646, 2023, doi: 10.3390/s23073646.
- [3] Z. Yang, Z. Xia, G. Yang, and Y. Lv, "A garbage classification method based on a small convolution neural network," *Sustainability*, vol. 14, no. 22, p. 14735, 2022, doi: 10.3390/su142214735.
- [4] C. Hu, B. B. Sapkota, J. A. Thomasson, and M. V Bagavathiannan, "Influence of image quality and light consistency on the performance of convolutional neural networks for weed mapping," *Remote Sens. (Basel)*, vol. 13, no. 11, p. 2140, 2021, doi: 10.3390/rs13112140.
- [5] S. Sivamani, S. I. Chon, D. Y. Choi, D. H. Lee, and J. H. Park, "Importance of adaptive photometric augmentation for different convolutional neural networks," *Computers, Materials & Continua*, vol. 72, no. 3, pp. 4433–4452, 2022, doi: 10.32604/cmc.2022.026759.
- [6] M. Cabrera, "An evaluation of CNN models and data augmentation techniques in hierarchical localization of mobile robots," *Evolving Systems*, 2024, doi: 10.1007/s12530-024-09604-6.
- [7] E. Ramos, A. G. Lopes, and F. Mendonça, "Application of machine learning in plastic waste detection and classification: A systematic review," *Processes*, vol. 12, no. 8, p. 1632, 2024, doi: 10.3390/pr12081632.
- [8] M. I. B. Ahmed *et al.*, "Deep learning approach to recyclable products classification: Towards sustainable waste management," *Sustainability*, vol. 15, no. 14, p. 11138, 2023, doi: 10.3390/su151411138.
- [9] K. Alomar, H. I. Aysel, and X. Cai, "Data augmentation in classification and segmentation: A survey and new strategies," *J. Imaging*, vol. 9, no. 2, p. 46, 2023, doi: 10.3390/jimaging9020046.