

PERBANDINGAN TEKNIK OPTIMASI CNN UNTUK KLASIFIKASI GAMBAR SAMPAH BERBASIS DATASET KECIL DAN TIDAK SEIMBANG

Siti Huzzaemah Andzani¹, Martanto², Yudhistira Arie Wijaya³, Ahmad Faqih⁴, Rudi Kurniawan⁵,

Program Studi Teknik Informatika^{1,4,5}
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³

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

(*) Corresponding Author : sitihuzzaemahadzani@gmail.com
Published : 31 Desember 2025

Abstract— Household waste management is one of the major challenges in supporting environmental sustainability. One modern approach to address this issue is the application of image classification technology using Convolutional Neural Network (CNN) models. However, waste-image datasets are often limited in size and suffer from class imbalance, which negatively impacts model accuracy. This study aims to evaluate the performance of a CNN model in classifying household waste images under four training scenarios: baseline, data augmentation, weighted loss, and their combination. Experimental results show that data augmentation provides the most significant performance improvement, achieving an accuracy of 82.81% and an F1-score of 82.59%. Meanwhile, weighted loss is effective in boosting recall but does not outperform augmentation in overall performance. These findings indicate that data augmentation is a more optimal strategy when dealing with small and imbalanced datasets. This research contributes insights into training optimization techniques for CNN-based household waste classification systems.

Keywords: CNN, Waste Classification, Data Augmentation, Weighted Loss, Imbalanced Data

Abstrak, Penanganan sampah rumah tangga merupakan salah satu tantangan penting dalam mendukung keberlanjutan lingkungan. Salah satu pendekatan modern untuk mengatasinya adalah pemanfaatan teknologi *image classification* dengan model *Convolutional Neural Network* (CNN). Namun, dataset sampah sering kali memiliki ukuran terbatas dan ketidakseimbangan kelas (*class imbalance*), sehingga berdampak pada akurasi model. Penelitian ini bertujuan untuk mengevaluasi performa model CNN dalam mengklasifikasikan gambar sampah rumah tangga dengan empat skenario pelatihan: *baseline*, *data augmentation*, *weighted loss*, dan *kombinasi keduanya*. Hasil eksperimen menunjukkan bahwa penerapan *data augmentation* memberikan peningkatan performa paling signifikan, dengan *accuracy* 82,81% dan *F1-score* 82,59%. Sementara itu, *weighted loss* terbukti efektif dalam meningkatkan *recall*, tetapi tidak menghasilkan performa keseluruhan yang lebih baik dibandingkan *augmentation*. Temuan ini menegaskan bahwa teknik *augmentation* merupakan strategi yang lebih optimal dalam kondisi dataset kecil dan tidak seimbang. Penelitian ini memberikan kontribusi dalam pemanfaatan metode optimasi pelatihan CNN untuk aplikasi klasifikasi sampah rumah tangga.

Kata Kunci: CNN, Klasifikasi Sampah, Data Augmentation, Weighted Loss, Ketidakseimbangan Data

INTRODUCTION

Permasalahan sampah rumah tangga di Indonesia terus meningkat seiring pertumbuhan penduduk dan pola konsumsi yang berubah, dengan fraksi organik sebagai komponen terbesar serta non-organik seperti plastik dan logam yang sulit

terurai (Ferdinan & al., 2022)(Abubakar & al., 2022). Ketidakefisienan pemilahan di sumber menyebabkan penumpukan sampah di landfill serta meningkatnya pencemaran lingkungan(Martianto & al., 2024). Faktor sosial dan kebiasaan masyarakat turut memengaruhi efektivitas pengelolaan sampah (Resolute, 2024). Oleh karena itu, teknologi

berbasis visi komputer, khususnya *Convolutional Neural Network* (CNN), semakin banyak digunakan untuk otomatisasi pemilahan sampah karena kemampuannya dalam mengenali pola visual secara efisien (Malik, 2022).

Namun, penerapan CNN pada data sampah nyata menghadapi dua kendala utama, yaitu ukuran dataset yang kecil serta ketidakseimbangan kelas yang membuat model bias terhadap kelas mayoritas (Reza & Ma, 2024)(Hellín & al., 2024). Selain itu, variasi visual yang terbatas seperti perbedaan latar belakang dan pencahayaan mengurangi kemampuan generalisasi model (Wei & al., 2023)(Scholz & al., 2024). Studi sebelumnya menunjukkan bahwa *data augmentation* efektif meningkatkan keragaman citra (Zhao, 2024) dan *weighted loss* mampu mengurangi bias model terhadap kelas minoritas (Turn et al., 2025)(Song, 2024). Namun, sebagian besar penelitian hanya menguji salah satu pendekatan dan menggunakan dataset yang relatif seimbang, sehingga belum memberikan pemahaman komparatif yang komprehensif.

Menanggapi gap tersebut, penelitian ini melakukan eksperimen terkontrol pada empat konfigurasi pelatihan CNN baseline, *augmentation only*, *weighted-loss only*, dan *hybrid* dengan arsitektur dan *hyperparameter* yang dijaga konstan agar perubahan performa dapat diatribusikan langsung pada perlakuan yang diuji. Hasil menunjukkan bahwa *data augmentation* memberikan performa terbaik dengan akurasi 82,81% dan F1-score 82,59%, sementara *weighted loss* meningkatkan *recall* kelas minoritas namun memperbesar *false positive*, sehingga menurunkan F1-score (71,10%) (hasil eksperimen skripsi). Model hybrid belum melampaui performa augmentasi sehingga diperlukan pengaturan parameter lebih lanjut. Temuan ini memberi kontribusi penting bagi pengembangan sistem klasifikasi sampah otomatis berbasis AI untuk mendukung implementasi *smart waste management* yang lebih efisien di Indonesia.

KERANGKA TEORITIS

A. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan arsitektur *deep learning* yang dirancang untuk mempelajari fitur visual melalui proses konvolusi bertingkat. CNN terdiri dari *convolutional layer*, *pooling layer*, *activation function*, dan *fully connected layer* yang bekerja secara hierarkis untuk mengekstraksi pola dari citra, mulai dari tepi sederhana hingga representasi objek kompleks (Krichen, 2023)(Alom et al., 2021). Keunggulan CNN terletak pada kemampuannya mempertahankan informasi spasial sehingga lebih robust terhadap rotasi, translasi, dan variasi pencahayaan (Purwono, 2023). Pada konteks klasifikasi sampah, CNN digunakan untuk membedakan citra organik dan non-organik berdasarkan tekstur, warna, dan pola bentuk.

B. Masalah Ketidakseimbangan Kelas pada Dataset Citra

Ketidakseimbangan kelas (*class imbalance*) terjadi ketika jumlah sampel antar kelas tidak seimbang, seperti pada dataset 581 citra sampah yang digunakan dalam penelitian ini. Kondisi tersebut membuat model lebih sering mengklasifikasikan input ke kelas mayoritas sehingga menurunkan performa *recall* kelas minoritas (Nnamoko & Barrowclough, 2022) (Chen, 2024). Pada kasus ini, kelas *non-organik* memiliki jumlah lebih besar dibanding *organik*, sehingga diperlukan teknik penyeimbang yang dapat meningkatkan sensitivitas model.

C. Data Augmentation

Data augmentation merupakan teknik yang digunakan untuk memperluas variasi dataset melalui transformasi citra seperti rotasi, flipping, zooming, perubahan kecerahan, dan translasi. Teknik ini terbukti efektif meningkatkan generalisasi model pada dataset kecil dan tidak seimbang (Z. Zhong et al., 2025)(Wei & al., 2023). Pada penelitian ini, augmentasi diterapkan *on-the-fly* sehingga setiap epoch menghasilkan variasi citra berbeda, membantu model belajar pola visual lebih luas dan mengurangi risiko *overfitting*.

D. Weighted Loss Function

Weighted loss merupakan pendekatan untuk mengurangi bias CNN terhadap kelas mayoritas dengan cara memberikan bobot lebih besar pada kelas minoritas dalam perhitungan *loss* (Zheng & Gu, 2021) (Song, 2024). Dengan demikian, kesalahan klasifikasi pada kelas minoritas memiliki penalti lebih besar sehingga model terdorong untuk mengenali sampel kelas tersebut secara lebih akurat. Teknik ini sangat relevan pada dataset dengan distribusi tidak merata seperti pada klasifikasi sampah organik dan non-organik.

E. Kombinasi Augmentation dan Weighted Loss

Secara teoretis, data augmentation dan weighted loss memiliki peran saling melengkapi. Augmentasi menambah keragaman visual pada level data, sedangkan weighted loss menyeimbangkan *gradient update* pada level model (Zou & Wang, 2024) (Dablain et al., 2024). Kombinasi keduanya berpotensi menghasilkan model yang lebih stabil terhadap *class imbalance*. Namun, beberapa penelitian melaporkan bahwa interaksi kedua pendekatan ini tidak selalu linear dan memerlukan pengaturan parameter yang cermat.

f. Pengembangan Hipotesis

Berdasarkan kerangka teori di atas, hipotesis dalam penelitian ini dirumuskan sebagai berikut:

H1: Penerapan *data augmentation* meningkatkan akurasi dan *F1-score* model CNN dibandingkan konfigurasi *baseline*.

→ Berdasarkan teori generalisasi model dan efektivitas augmentasi pada dataset kecil (Y. Zhong et al., 2025)(Wei & al., 2023).

H2: Penerapan *weighted loss* meningkatkan *recall* kelas minoritas dibandingkan *baseline*.

→ Didukung teori bahwa pembobotan meningkatkan kontribusi kelas minoritas (Zheng & Gu, 2021); (Song, 2024).


H3: Kombinasi *data augmentation* dan *weighted loss* (model hybrid) menghasilkan performa yang lebih baik dibandingkan kedua pendekatan secara terpisah.

→ Berdasarkan teori sinergi augmentasi dan

balancing pada level data serta model (Zou & Wang, 2024)

MATERIALS AND METHODS

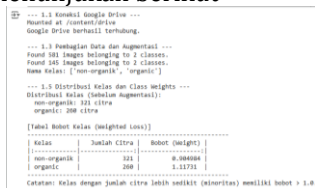
Metode riset pada penelitian ini disusun untuk memberikan pendekatan sistematis dalam mengevaluasi efektivitas *data augmentation* dan *weighted loss* dalam mengoptimalkan kinerja Convolutional Neural Network (CNN) pada klasifikasi sampah rumah tangga. Mengingat dataset yang digunakan berukuran kecil dan memiliki ketidakseimbangan kelas, rancangan eksperimen dilakukan secara terkontrol agar setiap perlakuan dapat dianalisis secara objektif. Oleh karena itu, prosedur penelitian mencakup tahapan mulai dari pengumpulan dan pemeriksaan dataset, eksplorasi karakteristik data, preprocessing citra, perancangan arsitektur CNN, penerapan fungsi kerugian berbobot, hingga pengujian empat konfigurasi model secara terpisah. Setiap tahap diarahkan untuk memastikan reproduktibilitas, validitas, serta kemampuan model dalam menghasilkan performa klasifikasi yang stabil dan akurat sesuai tujuan penelitian. Dengan pendekatan ini, metode riset tidak hanya menjadi dasar pelaksanaan eksperimen, tetapi juga menjadi kerangka evaluasi yang memungkinkan penilaian komprehensif terhadap pengaruh masing-masing teknik optimasi yang diuji dalam penelitian ini. Untuk metodologi penelitian ditunjukkan pada Gambar 1 berikut.



Gambar 1 Tahapan Penelitian

Pengumpulan Data


Penelitian ini dimulai dengan tahap pengumpulan dataset yang digunakan merupakan dataset publik “Sampah Daur Ulang” dari Kaggle, terdiri dari 581 citra yang diklasifikasikan ke dalam dua kelas: organik (260 citra) dan non-organik (321 citra). Seluruh citra melalui proses pembersihan awal untuk menghilangkan duplikasi dan citra tidak relevan. Pembagian data dilakukan secara *stratified* dengan proporsi 70% pelatihan, 15% validasi, dan 15% pengujian sehingga distribusi kelas tetap seimbang pada setiap subset. Pada gambar 2 menunjukkan berikut



Gambar 2 Hasil Pengumpulan Data

EDA

Tahap EDA dilakukan untuk memahami karakteristik data dan mendeteksi ketidakseimbangan kelas. Analisis meliputi visualisasi distribusi kelas, pemeriksaan variasi latar belakang, pencahayaan, serta perbedaan fitur visual antar kelas. Hasil EDA menunjukkan bahwa dataset memiliki variasi visual terbatas dan distribusi data yang tidak seimbang sehingga teknik augmentasi dan *class weighting* diperlukan untuk meningkatkan performa model.



Gambar 3 Hasil Pengumpulan Data

Preprocessing Data

Setelah tahap EDA lalu melakukan Preprocessing citra dilakukan untuk memastikan seluruh gambar berada dalam format yang seragam, stabil selama pelatihan, serta siap diproses oleh jaringan CNN. Proses ini mencakup ukuran akhir gambar, strategi normalisasi, langkah-langkah augmentasi, dan mekanisme penerapannya sebagai berikut:

Ukuran Akhir Gambar

Seluruh citra di-*resize* menjadi 224×224 piksel sebelum dimasukkan ke model CNN. Pemilihan

ukuran ini didasarkan pada standar umum yang digunakan dalam banyak arsitektur CNN modern serta pretrained models. Resolusi 224×224 dipilih untuk menjaga keseimbangan antara detail visual dan efisiensi komputasi.

Strategi Normalisasi

Normalisasi piksel bertujuan untuk mempercepat konvergensi model dan menstabilkan proses pelatihan. Dua pendekatan yang dipertimbangkan yaitu:

1. Rescaling 0–1 (default): nilai piksel dibagi 255 sehingga berada pada rentang $[0,1]$. Strategi ini digunakan sebagai default dalam seluruh eksperimen.
2. Mean/Std Normalization (opsional): digunakan bila menerapkan pretrained models seperti ImageNet, yaitu mengurangi *mean* dan membagi *standard deviation* per-channel. Pendekatan ini hanya digunakan pada konfigurasi eksperimen tertentu.

Pada penelitian ini, metode utama yang digunakan adalah rescaling 0–1 untuk menjaga konsistensi dengan karakteristik dataset lokal.

Augmentasi Data

Augmentasi diterapkan on-the-fly selama proses pelatihan. Teknik ini dipilih karena:

- Tidak memerlukan penyimpanan tambahan (augmentasi tidak disimpan sebagai file baru),
- Variasi transformasi berubah setiap epoch sehingga meningkatkan kemampuan generalisasi model pada dataset kecil,
- Sesuai dengan praktik terbaik dalam pelatihan CNN.

Transformasi augmentasi yang digunakan meliputi:

1. Rotasi
2. Flip horizontal
3. Zoom
4. Brightness/Jitter adjustment
5. Translation (shifting)

Seluruh parameter augmentasi disimpan dalam berkas konfigurasi agar dapat direproduksi dan dijalankan secara konsisten.

Pemodelan

A. Arsitektur Model CNN

Model CNN yang digunakan terdiri atas beberapa *convolutional layers* dengan kernel 3×3 , *ReLU activation*, *max pooling*, dan *fully connected*

layers pada bagian akhir. *Dropout* digunakan untuk mengurangi *overfitting*. Lapisan keluaran menggunakan *softmax* untuk klasifikasi dua kelas. Optimisasi menggunakan Adam optimizer dengan *learning rate* yang telah ditentukan. Model dirancang sederhana untuk memastikan bahwa peningkatan performa berasal dari teknik *augmentation* dan *weighted loss*, bukan dari kompleksitas arsitektur model.

B. Weighted Loss Function

Untuk mengatasi ketidakseimbangan kelas, penelitian menerapkan *class weights* berdasarkan rumus *inverse frequency* sehingga kelas dengan jumlah sampel lebih sedikit memiliki bobot lebih besar. Bobot kelas yang digunakan adalah: organik ≈ 1.117 dan non-organik ≈ 0.904 . Weighted Cross-Entropy digunakan sebagai fungsi *loss* pada konfigurasi *weighted-loss* dan *hybrid* untuk memperkuat pembelajaran pada kelas minoritas

Evaluasi Model

Evaluasi performa dilakukan menggunakan metrik:

1. akurasi,
2. precision,
3. recall,
4. F1-score,
5. macro-F1,
6. confusion matrix.

Metrik-metrik ini dipilih karena akurasi saja tidak cukup mewakili kualitas model pada dataset yang tidak seimbang. Analisis dilakukan untuk menilai keunggulan masing-masing konfigurasi serta pengaruh augmentasi dan weighted loss terhadap performa klasifikasi. Tetapi akurasi validasi hanya berada di kisaran 84–87%, kembali memperkuat indikasi *overfitting*. Secara keseluruhan, model belajar sangat baik pada data training tetapi belum mampu menggeneralisasi dengan baik pada data validasi. Oleh karena itu, diperlukan strategi optimasi seperti augmentasi data atau *weighted-loss* untuk meningkatkan performa generalisasi model.


RESULTS AND DISCUSSION

A. Hasil Eksperimen

Penelitian ini menguji empat konfigurasi model CNN, yaitu *baseline*, *augmentation-only*, *weighted-loss-only*, dan *hybrid*. Seluruh model dilatih menggunakan arsitektur dan *hyperparameter* yang sama agar perbedaan performa dapat diatribusikan secara langsung pada perlakuan yang diberikan. Dataset terdiri dari 581 citra dengan proporsi pelatihan, validasi, dan pengujian yang dibagi secara *stratified* sehingga distribusi kelas tetap representatif.

a. Baseline Model


Model *baseline*, yang dilatih tanpa augmentasi maupun *class weights*, menunjukkan performa terendah. Kondisi ketidakseimbangan kelas menyebabkan model lebih sering memprediksi kelas mayoritas dan menghasilkan penurunan signifikan pada *recall* kelas minoritas. Hal ini sejalan dengan karakteristik *class imbalance* yang berdampak langsung pada sensitivitas model. Disajikan Pada Gambar berikut.



Gambar 4. Hasil Model Baseline

Confusion matrix pada eksperimen *baseline* menunjukkan bahwa model mampu mengklasifikasikan kelas *organic* dengan baik, ditandai dengan 39 prediksi benar dan hanya 3 kesalahan. Namun, performa pada kelas *non-organic* masih kurang optimal karena terdapat 16 sampel yang salah diprediksi sebagai *organic* dan hanya 25 yang terklasifikasi dengan benar. Hasil ini sejalan dengan laporan klasifikasi, di mana kelas *organic* memiliki recall tinggi (0.93), sedangkan kelas *non-organic* hanya mencapai recall 0.61. Secara keseluruhan, akurasi model sebesar 77% menunjukkan performa *baseline* yang cukup baik, tetapi masih memerlukan peningkatan terutama dalam membedakan sampah *non-organic*. ga >95%, tetapi akurasi validasi hanya berada di kisaran 84–87%, kembali memperkuat indikasi *overfitting*. Secara keseluruhan, model belajar

b. Augmentation-Only Model

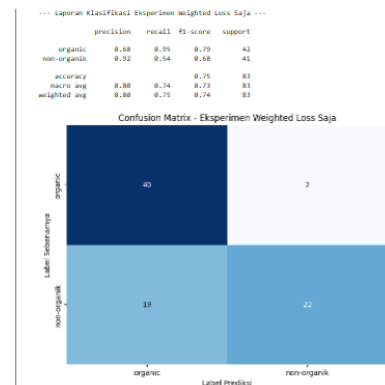


Gambar 5 . Hasil Model Augmentation-only

Confusion matrix pada eksperimen *augmentasi saja* menunjukkan peningkatan performa dibanding baseline, terutama pada kelas *non-organic*. Model berhasil mengklasifikasikan 39 sampel *organic* dengan benar dan hanya melakukan 3 kesalahan, sementara pada kelas *non-organic* terdapat 29 prediksi benar dan 12 kesalahan. Peningkatan ini tercermin pada recall kelas *non-organic* yang naik menjadi 0.71 dari sebelumnya 0.61, menandakan augmentasi membantu model mengenali variasi visual pada kelas tersebut. Dengan akurasi keseluruhan 82%, model dengan augmentasi menunjukkan generalisasi yang lebih baik dan distribusi error yang lebih seimbang dibanding eksperimen baseline.

c. Weighted-Loss-Only Model

Penerapan *class weighting* meningkatkan *recall* kelas minoritas secara signifikan karena bobot kelas minoritas diberikan lebih tinggi (*organik* ≈ 1.117 ; *non-organik* ≈ 0.904). Namun, model ini mengalami peningkatan *false positive* yang menyebabkan penurunan F1-score menjadi 71,10%. Temuan ini mengonfirmasi bahwa *weighted loss* efektif untuk mengatasi bias, tetapi sensitif terhadap distribusi fitur yang kurang beragam tanpa dukungan augmentasi. Disajikan Pada Gambar berikut.




Gambar 6. Weighted-Loss-Only Model

Confusion matrix pada eksperimen *weighted loss saja* menunjukkan bahwa model mampu mengenali kelas *organic* dengan sangat baik, ditandai dengan 40 prediksi benar dan hanya 2 kesalahan. Namun, performa pada kelas *non-organic* masih terbatas, terlihat dari 22 prediksi benar dan 19 kesalahan. Hal ini sejalan dengan nilai recall kelas *non-organic* yang hanya mencapai 0.54, lebih rendah dibanding kelas *organic* yang memiliki recall 0.95. Meskipun akurasi keseluruhan sebesar 75% masih cukup baik, penggunaan *weighted loss* saja belum memberikan peningkatan signifikan pada kemampuan model dalam membedakan kelas *non-organic*, sehingga metode ini lebih efektif ketika dikombinasikan dengan teknik augmentasi.

d. Model Hybrid (Augmentation + Weighted Loss)

Konfigurasi hybrid menunjukkan performa lebih baik dibanding *weighted-loss-only*, namun belum melampaui augmentasi. Hasil ini mengindikasikan bahwa kombinasi kedua teknik memerlukan pengaturan yang lebih optimal, seperti penyesuaian tingkat augmentasi atau pembobotan kelas yang lebih stabil. Interaksi antara variasi visual yang dihasilkan augmentasi dan penalti kelas minoritas dalam fungsi *loss* tidak bersifat linear, sehingga tuning parameter menjadi faktor penting untuk mencapai sinergi yang maksimal. Disajikan Pada Gambar berikut.



**Gambar 7 Hasil Augmentation +
Weighted Loss**

Confusion matrix pada eksperimen *hybrid*—yang menggabungkan augmentasi dan weighted loss—menunjukkan performa model yang paling seimbang. Model berhasil mengklasifikasikan 39 sampel *organic* dengan benar dan hanya membuat 3 kesalahan, sementara pada kelas *non-organic* tercatat 29 prediksi benar dan 12 kesalahan. Hasil ini didukung oleh peningkatan f1-score dan akurasi keseluruhan sebesar 82%, yang menjadi salah satu nilai tertinggi dibandingkan eksperimen lain. Kombinasi teknik augmentasi untuk menambah variasi data dan weighted loss untuk menangani ketidakseimbangan kelas terbukti membantu model mengenali kedua kelas dengan lebih stabil, sehingga menghasilkan generalisasi yang lebih baik secara keseluruhan.

CONCLUSION

Hasil penelitian menunjukkan bahwa *data augmentation* merupakan pendekatan paling efektif dalam meningkatkan performa CNN pada dataset sampah berukuran kecil dan tidak seimbang. Hal ini sejalan dengan literatur yang menyatakan bahwa augmentasi mampu menambah keragaman citra dan mengurangi risiko *overfitting* pada model *deep learning* (Y. Zhong et al., 2025). Tingginya F1-score pada konfigurasi augmentasi memperlihatkan bahwa model mampu mempertahankan keseimbangan antara precision dan recall.

Sementara itu, weighted loss terbukti meningkatkan sensitivitas model terhadap kelas minoritas dengan menaikkan recall. Namun peningkatan *false positive* mengakibatkan penurunan F1-score, sesuai dengan penelitian sebelumnya yang menyoroti tantangan stabilitas *gradient update* pada kondisi ketidakseimbangan data (Song, 2024)(Zheng &

Gu, 2021). Dengan demikian, weighted loss efektif sebagai penyeimbang, tetapi tidak cukup kuat tanpa dukungan variasi fitur dari augmentasi.

Model hybrid tidak menghasilkan performa tertinggi, karena parameter kombinasi augmentasi dan *class weights* belum optimal. Temuan ini menguatkan teori bahwa sinergi kedua pendekatan memerlukan keseimbangan yang tepat agar noise dari augmentasi tidak mengganggu proses pembobotan kelas (Dablain et al., 2024).

Secara keseluruhan, penelitian ini menunjukkan bahwa augmentasi merupakan strategi yang dominan dalam meningkatkan generalisasi model pada dataset kecil, sedangkan weighted loss berperan sebagai mekanisme pelengkap untuk meningkatkan sensitivitas kelas minoritas. Kombinasi keduanya tetap menjanjikan apabila dilakukan tuning parameter yang lebih spesifik pada konfigurasi data dan karakter citra sampah.

REFERENCE

- Abubakar, I. R., & al., et. (2022). Environmental Sustainability Impacts of Solid Waste Management Practices in the Global South. *International Journal of Environmental Research and Public Health*, 19(19), 12717.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., & Asari, V. K. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications and future directions. *Journal of Big Data*, 8, 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Chen, W. (2024). A survey on imbalanced learning: latest research and future challenges. *Artificial Intelligence Review*. <https://doi.org/10.1007/s10462-024-10759-6>
- Dablain, D., Corizzo, R., & Japkowicz, N. (2024). Understanding CNN fragility when learning with imbalanced image data. *Machine Learning*. <https://doi.org/10.1007/s10994-023-06326-9>
- Ferdinan, S., & al., et. (2022). Household Waste Control Index towards Sustainable

- Waste Management. *Sustainability*, 14(21), 14403.
- Hellín, C. J., & al., et. (2024). Unraveling the Impact of Class Imbalance on Deep Learning Models for Medical Image Classification. *Applied Sciences*, 14(8), 3419.
- Krichen, M. (2023). Convolutional Neural Networks: A Survey. *Computers*, 12(8), 151. <https://doi.org/10.3390/2073-431X/12/8/151>
- Malik, M. (2022). Waste classification for sustainable development using image recognition with deep learning neural network models. *Sustainability*, 14(12), 7222. <https://doi.org/10.3390/su14127222>
- Martianto, D., & al., et. (2024). The Quantity and Composition of Household Food Waste: Implications for Policy. *PLOS ONE*, 19(6), e0305087.
- Nnamoko, N., & Barrowclough, J. (2022). Solid Waste Image Classification Using Deep Convolutional Neural Network. *Infrastructures*, 7(4), 47. <https://doi.org/10.3390/infrastructures7040047>
- Purwono, P. (2023). Understanding of Convolutional Neural Network (CNN): A Review. *International Journal of Robotics and Control Systems*, 2(4), 888. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Resolute, P. (2024). Applying Cultural Perspective in Indonesia Municipal Solid Waste Management Process. *Waste Management & Research*, 42(10), 873–881.
- Reza, A., & Ma, Y. (2024). A Data Augmentation Methodology to Reduce the Class Imbalance in Histopathology Images. *Journal of Imaging Informatics in Medicine*, 37, 1767–1782.
- Scholz, D., & al., et. (2024). Imbalance-Aware Loss Functions Improve Medical Image Classification. *Proceedings of The 7th International Conference on Medical Imaging with Deep Learning*, 1341–1356.
- Song, Z. (2024). An improved weighted cross-entropy-based convolutional neural network for auxiliary diagnosis of pneumonia. *Electronics*, 13(15), 2929. <https://doi.org/10.3390/electronics13152929>
- Turn, J., Cordova-Esparza, D.-M., & Romero-González, J.-A. (2025). A comprehensive survey of loss functions and metrics in deep learning. *Artificial Intelligence Review*, 58, 195. <https://doi.org/10.1007/s10462-025-11198-7>
- Wei, S., & al., et. (2023). An Efficient Data Augmentation Method for Automatic Modulation Recognition from Low-Data Imbalanced-Class Regime. *Applied Sciences*, 13(5), 3177.
- Zhao, X. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*. <https://doi.org/10.1007/s10462-024-10721-6>
- Zheng, Y., & Gu, J. (2021). A class-weighted convolutional neural network for garbage image classification under data imbalance conditions. *Waste Management*, 120, 680–688.
- Zhong, Y., Zhou, W., & Wang, Z. (2025). A survey of data augmentation in domain generalization. *Neural Processing Letters*, 57, 34. <https://doi.org/10.1007/s11063-025-11747-9>
- Zhong, Z., Zheng, L., Kang, G., Li, S., & Yang, Y. (2025). Random erasing data augmentation revisited: A survey and new insights. *Knowledge-Based Systems*.
- Zou, R., & Wang, N. (2024). Imbalanced data parameter optimization of convolutional neural networks based on analysis of variance. *Applied Sciences*, 14(19), 9071. <https://doi.org/10.3390/app14199071>