

OPTIMALISASI AKURASI MODEL DEEP LEARNING PADA KLASIFIKASI SAMPAH PLASTIK MENGGUNAKAN STRATEGI FINE-TUNING MOBILENETV2

Difilal Syaban Rizkiyan¹; Dian Ade Kurnia²; Yudhistira Arie Wijaya³; Nining Rahaningsih⁴; Willy Prihartono⁵;

Program Studi Teknik Informatika¹
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³
Program Studi Komputerisasi Akuntansi^{4,5}

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
difilalsyabanrizkiyan475@gmail.com

(*) Corresponding Author : difilalsyabanrizkiyan475@gmail.com
Published : 31 Desember 2025

Abstract—Effective plastic waste management requires reliable automatic sorting systems, especially in multi-class scenarios where different types of plastic share similar visual characteristics. This study aims to analyze the effect of a partial fine-tuning strategy on MobileNetV2 for classifying seven classes of plastic waste, by comparing it with a baseline model that only trains the classification head on ImageNet pre-trained features. The dataset consists of 3,500 plastic waste images evenly distributed across seven classes and split into training, validation, and test sets with proportions of 70%, 15%, and 15%, respectively. All images are resized to 256×256 pixels and processed using standard data augmentation. The baseline model uses a pre-trained MobileNetV2 backbone (frozen base) followed by global average pooling, dropout, and a 7-class dense layer, trained with the Adam optimizer (learning rate 1e-3) and sparse categorical cross-entropy loss. In the fine-tuning scenario, approximately 40 of the last layers of MobileNetV2 are unfrozen and retrained with Adam (learning rate 1e-4) under the same data configuration. Experimental results on the test set show that the baseline model achieves 91.62% accuracy and a macro F1-score of 0.9164, while the fine-tuned model improves performance to 93.71% accuracy and a macro F1-score of 0.9370. These findings indicate that partial fine-tuning of MobileNetV2 yields consistent performance gains without increasing inference-time architectural complexity, making it relevant for deployment in computer-vision-based automatic plastic waste sorting systems.

Keywords: plastic waste, MobileNetV2, fine-tuning, image classification, deep learning

Abstrak—Pengelolaan sampah plastik yang efektif memerlukan sistem pemilahan otomatis yang andal, terutama pada skenario multi-kelas dengan kemiripan visual tinggi antar jenis plastik. Penelitian ini bertujuan menganalisis pengaruh strategi fine-tuning parsial MobileNetV2 terhadap kinerja klasifikasi tujuh kelas sampah plastik, dengan membandingkannya terhadap model baseline yang hanya melatih classification head pada fitur pra-latih ImageNet. Dataset yang digunakan terdiri atas 3.500 citra sampah plastik yang terbagi seimbang ke dalam tujuh kelas dan dipisahkan menjadi data latih, validasi, dan uji dengan proporsi 70% : 15% : 15%. Seluruh citra di-resize menjadi 256×256 piksel dan diproses melalui augmentasi standar. Model baseline menggunakan MobileNetV2 pra-latih (base dibekukan), global average pooling, dropout, dan lapisan dense 7 kelas, dilatih dengan optimizer Adam (learning rate 1e-3) dan loss sparse categorical cross-entropy. Pada skenario fine-tuning, sekitar 40 lapisan terakhir MobileNetV2 di-unfreeze dan dilatih ulang dengan Adam (learning rate 1e-4) menggunakan konfigurasi data yang sama. Hasil pengujian menunjukkan bahwa model baseline mencapai akurasi 91,62% dan macro F1-score 0,9164, sedangkan model fine-tuning meningkat menjadi akurasi 93,71% dan macro F1-score 0,9370. Temuan ini menunjukkan bahwa fine-tuning parsial MobileNetV2 memberikan peningkatan kinerja yang konsisten tanpa menambah kompleksitas arsitektur inferensi, sehingga relevan untuk diterapkan pada sistem pemilahan sampah plastik otomatis berbasis visi komputer.

Kata Kunci: sampah plastik, MobileNetV2, fine-tuning, klasifikasi citra, deep learning.

INTRODUCTION

Perkembangan kecerdasan buatan dan deep learning dalam bidang Informatika telah mendorong lahirnya berbagai sistem cerdas untuk mendukung otomatisasi di sektor industri, layanan publik, dan pengelolaan lingkungan (Alzubaidi et al., 2023). Penerapan computer vision memungkinkan citra digital dianalisis secara otomatis untuk tugas pengenalan objek, klasifikasi, dan pengambilan keputusan berbasis data (Sarker, 2021). Dalam konteks pengelolaan sampah, terutama sampah plastik, kemampuan ini menjadi penting untuk mendukung sistem daur ulang yang lebih efektif dan berkelanjutan (Nayanathara Thathsarani Pilapitiya & Ratnayake, 2024). Permasalahan sampah plastik yang terus meningkat menuntut solusi teknologi yang tidak hanya akurat, tetapi juga efisien dan dapat diimplementasikan pada skala luas (Fan et al., 2023).

Di lapangan, proses pemilahan sampah umumnya masih dilakukan secara manual, bergantung pada tenaga kerja dan konsistensi petugas, sehingga rawan kesalahan dan sulit diskalakan ketika volume sampah tinggi dan komposisinya beragam (Lu & Chen, 2022). Pendekatan ini menyulitkan penerapan pemilahan terpisah untuk jenis plastik tertentu yang memiliki nilai daur ulang lebih tinggi (Pučnik et al., 2024). Penelitian sebelumnya menunjukkan bahwa model convolutional neural network (CNN) mampu mencapai akurasi yang baik pada tugas klasifikasi sampah, namun kinerjanya sering menurun ketika berhadapan dengan data dunia nyata yang bising, tidak seimbang, dan latar belakang yang kompleks (Yang et al., 2022). Selain itu, perbedaan distribusi antara dataset pra-latih generik seperti ImageNet dan citra sampah plastik dapat memengaruhi kemampuan generalisasi model jika tidak diadaptasikan dengan baik (Kim et al., 2022). Kondisi ini membuat model masih berpotensi mengalami kesalahan pada kelas-kelas plastik yang mirip secara visual, misalnya antarjenis botol atau antara wadah dan kantong plastik (Bobulski & Kubanek, 2021).

Arsitektur CNN ringan seperti MobileNetV2 banyak dikaji karena menawarkan kompromi yang baik antara akurasi dan efisiensi komputasi, sehingga cocok untuk diimplementasikan pada perangkat edge dan sistem IoT (Yong et al., 2023). Pemanfaatan bobot pra-latih (pre-trained weights) dari ImageNet melalui transfer learning memungkinkan model beradaptasi dengan domain baru, termasuk citra sampah plastik, meskipun jumlah data terbatas (Hosna et al., 2022). Namun,

penggunaan MobileNetV2 hanya sebagai frozen feature extractor belum tentu menghasilkan representasi fitur yang optimal untuk membedakan variasi halus antar kelas plastik yang mirip secara visual (Davila et al., 2024).


Salah satu pendekatan yang berkembang adalah penerapan strategi fine-tuning pada sebagian lapisan (partial unfreezing) untuk menyesuaikan bobot model dengan karakteristik dataset target (Alfano et al., 2024). Strategi ini berpotensi meningkatkan akurasi dan kemampuan generalisasi tanpa menambah kompleksitas model secara berlebihan, sehingga tetap relevan untuk skenario implementasi dengan keterbatasan sumber daya komputasi (Maeda-Gutiérrez et al., 2020). Meskipun beberapa studi telah mengkaji klasifikasi sampah berbasis CNN dan penggunaan MobileNetV2, masih terbatas penelitian yang secara sistematis membandingkan model baseline tanpa fine-tuning dengan model MobileNetV2 yang di-fine-tune pada dataset sampah plastik multi-kelas (Malik et al., 2022).

Penelitian ini memfokuskan kajian pada optimalisasi akurasi model deep learning untuk klasifikasi tujuh kelas sampah plastik menggunakan strategi fine-tuning MobileNetV2 pada dataset Recyclable and Household Waste Classification (subset plastik) dari Kaggle. Dengan membandingkan kinerja model baseline dan model yang di-fine-tune, penelitian ini diharapkan dapat menjawab kebutuhan akan model klasifikasi sampah plastik yang akurat, efisien, dan siap diintegrasikan ke dalam sistem pemilahan otomatis serta perangkat edge berbasis IoT (Rahman et al., 2022).

MATERIALS AND METHODS

Tahapan Metode Penelitian

Tahapan metode penelitian yang digunakan dalam studi ini disajikan pada Gambar 1 Alur tersebut menunjukkan urutan proses mulai dari akuisisi data, pra-pemrosesan, optimasi parameter, exploratory data analysis (EDA), pemodelan MobileNetV2, evaluasi kinerja model, hingga analisis perbandingan antara model baseline dan model dengan fine-tuning parsial.



Gambar 1 Tahapan Metode Penelitian

Metode penelitian ini disusun dalam beberapa tahapan agar proses pengembangan dan evaluasi model MobileNetV2 dapat direplikasi dan dianalisis secara sistematis. Secara garis besar, tahapan metode penelitian meliputi: akuisisi data, pra-pemrosesan, optimasi parameter, exploratory data analysis (EDA), pemodelan MobileNetV2, evaluasi model, serta analisis perbandingan antara model baseline dan model dengan fine-tuning parsial. Penjelasan ringkas masing-masing tahapan adalah sebagai berikut.

Akuisisi Data

Pada tahap ini, peneliti mengunduh dan mengkurasi dataset citra sampah plastik dari Kaggle, yaitu Recyclable and Household Waste Classification. Subset tujuh kelas sampah plastik dipilih dari struktur folder asli, kemudian disusun ulang ke dalam direktori terpisah untuk keperluan pelatihan, validasi, dan pengujian.

Pra-pemrosesan (Pre-processing)

Tahap ini mencakup penyesuaian ukuran citra (misalnya resize ke 256x256 piksel), konversi format jika diperlukan, normalisasi nilai piksel, pembentukan label numerik, pembagian data ke dalam himpunan latih, validasi, dan uji (misalnya 70% : 15% : 15%), serta penerapan data augmentation dasar untuk meningkatkan keragaman data dan mengurangi risiko overfitting.

Optimasi Parameter

Pada tahap ini ditetapkan konfigurasi hiperparameter pelatihan, seperti pemilihan optimizer (misalnya Adam), nilai learning rate yang berbeda untuk model baseline dan skenario fine-tuning, ukuran batch, jumlah epoch maksimum, serta penerapan mekanisme early stopping. Penyetelan awal dilakukan secara iteratif sampai diperoleh kombinasi parameter yang stabil dan memberikan kinerja baik pada data validasi.

Exploratory Data Analysis (EDA)

Tahap EDA dilakukan untuk menganalisis karakteristik dataset, meliputi distribusi jumlah

sampel per kelas, variasi visual citra (pencahayaan, sudut pandang, latar belakang), serta contoh-contoh citra representatif dari setiap kelas. Hasil EDA digunakan sebagai dasar dalam merancang strategi pra-pemrosesan, data augmentation, dan interpretasi hasil eksperimen.

Pemodelan MobileNetV2

Pada tahap ini dibangun dua skenario model, yaitu model baseline MobileNetV2 dengan backbone pra-latih ImageNet yang dibekukan (hanya classification head yang dilatih) dan model MobileNetV2 dengan fine-tuning parsial pada sejumlah lapisan terakhir. Di atas backbone ditambahkan lapisan global average pooling, dropout, dan lapisan dense dengan tujuh neuron keluaran sesuai jumlah kelas sampah plastik.

Evaluasi Model

Model yang telah dilatih dievaluasi menggunakan data uji dengan metrik akurasi, precision, recall, dan F1-score, baik secara agregat (macro dan weighted average) maupun per kelas. Selain itu, disusun confusion matrix untuk melihat pola kesalahan klasifikasi antar kelas, sehingga kualitas prediksi model dapat dianalisis secara lebih mendalam.

RESULTS AND DISCUSSION

Hasil Pemodelan MobileNetV2

Tahap pemodelan mencakup dua skenario utama sebagaimana dijelaskan pada Bab III, yaitu model baseline (head-only) dan model dengan fine-tuning parsial pada backbone MobileNetV2.

Hasil Pelatihan Model Baseline MobileNetV2

Pada skenario baseline, MobileNetV2 dengan bobot pra-latih ImageNet digunakan sebagai backbone yang dibekukan (trainable = False). Di atas backbone ini ditambahkan lapisan GlobalAveragePooling2D, Dropout, dan Dense dengan tujuh neuron softmax sebagai classification head. Model dikompilasi dengan Adam (learning rate 1e-3) dan dilatih hingga 20 epoch menggunakan callback yang telah dijelaskan sebelumnya.

Tabel 1. Ringkasan Kinerja Model Baseline

No	Metrik	Nilai (Desimal)	Nilai (%)	Keterangan
1	Akurasi (Accuracy)	0,9162	91,62	481 prediksi benar dari 525 sampel test
2	Precision (Macro Average)	0,9173	91,73	Rata-rata presisi tujuh kelas

				(tanpa bobot)
3	Recall (Macro Average)	0,9162	91,62	Rata-rata recall tujuh kelas (tanpa bobot)
4	F1-score (Macro Average)	0,9164	91,64	Rata-rata F1-score tujuh kelas (tanpa bobot)
5	F1-score (Weighted Average)*	0,9164	91,64	Rata-rata F1 dengan pembobotan support kelas


Berdasarkan Tabel 1 menunjukkan bahwa model baseline MobileNetV2 (head-only) sudah memiliki kinerja cukup baik. Akurasi keseluruhan mencapai 91,62%, artinya 481 dari 525 sampel uji berhasil diprediksi dengan benar. Nilai precision, recall, dan F1-score macro average semuanya berada di kisaran 91,6–91,7%, sehingga rata-rata performa di tujuh kelas cukup seimbang tanpa ada kelas yang sangat tertinggal. Nilai F1-score weighted yang sama besar dengan macro menunjukkan bahwa karena jumlah sampel tiap kelas seimbang, pembobotan berdasarkan support tidak mengubah gambaran umum kinerja model. Kurva train/validation accuracy dan train/validation loss menunjukkan bahwa model baseline mampu mencapai konvergensi yang baik tanpa gejala overfitting yang ekstrem. Ringkasan kinerja pada test set ditampilkan pada Tabel 4. 5 Ringkasan Kinerja Model Baseline pada Test Set, sedangkan metrik per kelas (precision, recall, F1-score, dan support) disajikan pada Tabel 4. 6 Metrik Per Kelas Model Baseline. Confusion matrix model baseline divisualisasikan pada Gambar 4. 2 Confusion Matrix Model Baseline.

Tabel 2. Metrik Per Kelas Model Baseline

N o.	Kelas	Precision	Recall	F1-score	Support
1	botol_deterjen_plastik	0,947	0,960	0,954	75
2	wadah_makanan_plastik	0,987	1,000	0,993	75
3	kantong_belanja_plastik	0,920	0,920	0,920	75
4	botol_soda_plastik	0,847	0,813	0,830	75
5	plastik_sedotan	0,986	0,960	0,973	75

6	kantong_sampah_plastik	0,931	0,893	0,912	75
7	botol_air_plastik	0,803	0,867	0,833	75

Berdasarkan Tabel 3 menunjukkan bahwa kinerja model baseline sudah sangat baik untuk sebagian besar kelas. Kelas wadah_makanan_plastik dan plastik_sedotan memiliki nilai precision, recall, dan F1-score yang sangat tinggi (mendekati atau di atas 0,97), yang berarti model hampir selalu benar ketika mengenali kedua jenis sampah tersebut dan jarang melewatkannya. Kelas botol_deterjen_plastik dan kantong_belanja_plastik juga menunjukkan performa stabil dengan F1-score sekitar 0,92–0,95, menandakan keseimbangan yang baik antara kemampuan membedakan kelas dan menangkap seluruh sampel yang benar.



Gambar 2 Confusion Matrix Model Baseline

Berdasarkan Gambar 2 menunjukkan bahwa model baseline sudah cukup baik karena sebagian besar nilai berada pada diagonal utama, misalnya wadah_makanan_plastik terklasifikasi benar 75/75 dan plastik_sedotan 72/75. Namun masih terlihat beberapa pola kesalahan penting: botol_soda_plastik cukup sering dikira botol_air_plastik (11 sampel) dan sebaliknya botol_air_plastik keliru menjadi botol_soda_plastik (7 sampel), sedangkan kantong_belanja_plastik kadang salah diprediksi sebagai kantong_sampah_plastik (4 sampel) dan sebaliknya (4 sampel). Ada juga sedikit kekeliruan antara plastik_sedotan dan wadah_makanan_plastik. Pola ini menegaskan bahwa keterbatasan utama model baseline muncul pada kelas-kelas plastik yang bentuk dan tampilannya sangat mirip.

Secara umum, model baseline mencapai akurasi sekitar 0,9162 dengan macro F1-score sekitar 0,9164, yang menunjukkan bahwa pemanfaatan fitur pra-latih MobileNetV2 sudah memberikan

performa yang cukup baik pada tugas klasifikasi tujuh kelas sampah plastik.

Hasil Pelatihan Model MobileNetV2 dengan Fine-Tuning Parsial Pada skenario kedua, dilaksanakan fine-tuning partial unfreezing terhadap sekitar 40 lapisan terakhir backbone MobileNetV2 setelah tahap pelatihan head awal. Bobot terbaik dari pelatihan head (15 epoch, lr 1e-3) dimuat kembali, kemudian backbone diaktifkan (trainable = True) dan sebagian lapisan akhirnya di-unfreeze. Model dikompilasi ulang dengan Adam dan learning rate 1e-4, lalu dilatih selama 5 epoch tambahan.

Tabel 3 Ringkasan Kinerja Model Fine-Tuning

No	Metrik	Nilai (Desimal)	Nilai (%)	Keterangan
1	Akurasi (Accuracy)	0,9371	93,71	492 prediksi benar dari 525 sampel data uji
2	Precision (Macro Average)	0,9372	93,72	Rata-rata presisi tujuh kelas (tanpa bobot)
3	Recall (Macro Average)	0,9371	93,71	Rata-rata recall tujuh kelas (tanpa bobot)
4	F1-score (Macro Average)	0,9370	93,70	Rata-rata F1-score tujuh kelas (tanpa bobot)
5	F1-score (Weighted Average) *	0,9370	93,70	Rata-rata F1 dengan pembobotan support tiap kelas

Berdasarkan Tabel 4 menunjukkan bahwa model MobileNetV2 dengan fine-tuning memiliki kinerja yang sangat baik dan seimbang. Akurasi mencapai 93,71% dengan 492 prediksi benar dari 525 sampel uji, artinya hanya sedikit sampel yang salah klasifikasi. Nilai precision, recall, dan F1-score macro average semuanya sekitar 93,7%, menandakan bahwa rata-rata performa di tujuh kelas konsisten dan tidak ada kelas yang tertinggal jauh. Nilai F1-score weighted yang sama besar dengan macro (93,70%) juga mengindikasikan bahwa karena jumlah sampel tiap kelas seimbang,


kinerja model merata baik pada seluruh kelas sampah plastik.

Kurva pelatihan pada tahap fine-tuning menunjukkan perbaikan kinerja validasi tanpa peningkatan loss yang tajam, mengindikasikan proses penyesuaian bobot backbone yang relatif stabil. Ringkasan kinerja pada test set disajikan dalam Tabel 4 Ringkasan Kinerja Model Fine-Tuning pada Test Set, sedangkan performa per kelas disajikan dalam Tabel 4 Metrik Per Kelas Model Fine-Tuning. Confusion matrix untuk model ini divisualisasikan pada Gambar 2 Confusion Matrix Model Fine-Tuning.

Tabel 4 Metrik Per Kelas Model Fine-Tuning

N	Kelas	Precision	Recall	F1-score	Support
1	botol_deterjen_plastik	0,9863	0,9600	0,9730	75
2	wadah_makanan_plastik	1,0000	1,0000	1,0000	75
3	kantong_belanja_plastik	0,9459	0,9333	0,9396	75
4	botol_soda_plastik	0,8904	0,8667	0,8784	75
5	plastik_sedotan	0,9487	0,9867	0,9673	75
6	kantong_sampah_plastik	0,9091	0,9333	0,9211	75
7	botol_air_plastik	0,8800	0,8800	0,8800	75

Berdasarkan Tabel 4 menunjukkan bahwa model fine-tuning memberikan kinerja sangat baik di hampir semua kelas. Kelas wadah_makanan_plastik mencapai performa sempurna dengan precision, recall, dan F1-score 1,0000, artinya seluruh sampel pada kelas ini diklasifikasikan dengan benar. Kelas botol_deterjen_plastik dan plastik_sedotan juga memiliki F1-score tinggi ($\approx 0,97$), menunjukkan model sangat jarang keliru pada kedua jenis sampah tersebut. Kelas kantong_belanja_plastik dan kantong_sampah_plastik berada di kisaran F1-score $\approx 0,92-0,94$, yang masih menunjukkan kinerja stabil dan andal. Dua kelas yang relatif paling menantang tetap botol_soda_plastik dan botol_air_plastik dengan F1-score sekitar 0,878–0,880, namun nilainya sudah meningkat dibandingkan skenario baseline, sehingga kemampuan model membedakan jenis botol plastik menjadi lebih baik.



Gambar 3 Confusion Matrix Model Fine-Tuning Berdasarkan Gambar 3 menunjukkan bahwa model fine-tuning sudah sangat dominan mengisi diagonal utama, artinya sebagian besar sampel tiap kelas berhasil diprediksi dengan benar (misalnya wadah_makanan_plastik 75/75, plastik_sedotan 74/75, kantong_sampah_plastik 70/75). Kesalahan yang masih muncul terutama pada kelas yang mirip secara visual, seperti botol_soda_plastik yang kadang dikira botol_air_plastik (7 sampel), serta kantong_belanja_plastik yang sesekali keliru menjadi kantong_sampah_plastik (2 sampel) atau sebaliknya (4 sampel). Selain beberapa mis-klasifikasi antarbotol dan antarkantong tersebut, pola confusion matrix ini mengonfirmasi bahwa fine-tuning berhasil mengurangi kesalahan dan memperkuat pemisahan antar kelas sampah plastik. Model fine-tuning mencapai akurasi sekitar 0,9371 dengan macro F1-score sekitar 0,9370, menunjukkan peningkatan yang konsisten dibandingkan model baseline.

CONCLUSION

Penelitian ini bertujuan mengkaji pengaruh strategi fine-tuning parsial MobileNetV2 terhadap kinerja klasifikasi tujuh kelas sampah plastik berbasis citra, dengan membandingkannya terhadap model baseline yang hanya melatih classification head pada fitur pra-latih ImageNet. Berdasarkan rangkaian EDA, perancangan skema pelatihan, dan eksperimen pada data uji, beberapa kesimpulan utama dapat dirumuskan sebagai berikut.

Model baseline MobileNetV2 dengan backbone dibekukan (head only) menunjukkan kinerja yang sudah cukup baik pada tugas klasifikasi tujuh kelas sampah plastik, dengan akurasi test sekitar 91,62% dan nilai macro F1-score sekitar 91,64%. Hasil ini menegaskan bahwa pemanfaatan transfer learning dari model pra-latih merupakan pendekatan efektif

ketika dataset domain target berukuran menengah dan memiliki variasi kondisi pencitraan.

Penerapan strategi fine-tuning parsial pada sekitar 40 lapisan terakhir MobileNetV2 dengan learning rate yang lebih kecil menghasilkan peningkatan kinerja yang konsisten dibanding model baseline. Akurasi test naik menjadi sekitar 93,71%, sedangkan macro F1-score meningkat menjadi sekitar 93,70%, yang berarti terdapat kenaikan kinerja global sekitar 2 poin persentase. Peningkatan paling nyata terjadi pada kelas-kelas yang sebelumnya sulit dibedakan, khususnya botol_soda_plastik dan botol_air_plastik, sehingga menunjukkan bahwa penyesuaian sebagian bobot backbone terhadap domain sampah plastik mampu meningkatkan kemampuan diskriminasi antar kelas yang mirip secara visual.

Dari sudut pandang implementasi, hasil ini menunjukkan bahwa strategi fine-tuning parsial pada MobileNetV2 dapat memberikan kompromi yang baik antara akurasi dan efisiensi komputasi, karena arsitektur saat inferensi tetap ringan dan cocok untuk skenario edge/IoT, sementara peningkatan kinerja diperoleh tanpa menambah kompleksitas struktur model. Kontribusi penelitian ini bersifat terutama pada tataran metodologis dan eksperimental; implikasi terhadap peningkatan sistem pengelolaan sampah di lapangan masih bersifat potensial dan memerlukan pengujian lebih lanjut pada data operasional dan lingkungan nyata sebelum dapat dikaitkan secara langsung dengan capaian target SDGs.

REFERENCE

- Abbasian Ardakani, G., & al., et. (2024). Interpretation of Artificial Intelligence Models in Healthcare: Evaluation metrics, pitfalls and recommendations. *Journal of Ultrasound in Medicine*. <https://doi.org/10.1002/jum.16524>
- Alfano, P. D., Pastore, V. P., Rosasco, L., & Odone, F. (2024). Top-tuning: A study on transfer learning for an efficient alternative to fine tuning for image classification with fast kernel methods. *Image and Vision Computing*, 142. <https://doi.org/10.1016/j.imavis.2023.104894>
- Alzubaidi, L., Bai, J., Al-Sabaawi, A., Santamaría, J., Albahri, A. S., Al-dabbagh, B. S. N., Fadhel, M. A., Manoufali, M., Zhang, J., Al-Timemy, A. H., Duan, Y., Abdullah, A., Farhan, L., Lu, Y., Gupta, A., Albu, F., Abbosh, A., & Gu, Y. (2023). A survey on deep learning tools dealing with data scarcity: definitions, challenges, solutions, tips, and applications.

- Journal of Big Data*, 10(1).
<https://doi.org/10.1186/s40537-023-00727-2>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1).
<https://doi.org/10.1186/s40537-021-00444-8>
- Bobulski, J., & Kubanek, M. (2021). Deep Learning for Plastic Waste Classification System. *Applied Computational Intelligence and Soft Computing*, 2021.
<https://doi.org/10.1155/2021/6626948>
- Davila, A., Colan, J., & Hasegawa, Y. (2024). Comparison of fine-tuning strategies for transfer learning in medical image classification. *Image and Vision Computing*, 146, 105012.
<https://doi.org/10.1016/j.imavis.2024.105012>
- Fan, Z., Yan, Z., & Wen, S. (2023). Deep Learning and Artificial Intelligence in Sustainability: A Review of SDGs, Renewable Energy, and Environmental Health. *Sustainability (Switzerland)*, 15(18).
<https://doi.org/10.3390/su151813493>
- Hosna, A., Merry, E., Gyalmo, J., Alom, Z., Aung, Z., & Azim, M. A. (2022). Transfer learning: a friendly introduction. *Journal of Big Data*, 9(1).
<https://doi.org/10.1186/s40537-022-00652-w>
- Kim, H. E., Cosa-Linan, A., Santhanam, N., Jannesari, M., Maros, M. E., & Ganslandt, T. (2022). Transfer learning for medical image classification: a literature review. In *BMC Medical Imaging* (Vol. 22, Issue 1). BioMed Central Ltd.
<https://doi.org/10.1186/s12880-022-00793-7>
- Liang, H., & Seo, S. (2022). Lightweight Deep Learning for Road Environment Recognition. *Applied Sciences (Switzerland)*, 12(6).
<https://doi.org/10.3390/app12063168>
- Lu, W., & Chen, J. (2022). Computer vision for solid waste sorting: A critical review of academic research. *Waste Management*, 142, 29–43.
<https://doi.org/10.1016/j.wasman.2022.02.009>
- Maeda-Gutiérrez, V., Galván-Tejada, C. E., Zanella-Calzada, L. A., Celaya-Padilla, J. M., Galván-Tejada, J. I., Gamboa-Rosales, H., Luna-García, H., Magallanes-Quintanar, R., Guerrero Méndez, C. A., & Olvera-Olvera, C. A. (2020). Comparison of convolutional neural network architectures for classification of tomato plant diseases. *Applied Sciences (Switzerland)*, 10(4).
<https://doi.org/10.3390/app10041245>
- Malik, M., Sharma, S., Uddin, M., Chen, C. L., Wu, C. M., Soni, P., & Chaudhary, S. (2022). Waste Classification for Sustainable Development Using Image Recognition with Deep Learning Neural Network Models. *Sustainability (Switzerland)*, 14(12).
<https://doi.org/10.3390/su14127222>
- Mohammad, A. S., Jarullah, T. G., Al-Kaltakchi, M. T. S., Alshehabi Al-Ani, J., & Dey, S. (2024). IoT-MFaceNet: Internet-of-Things-Based Face Recognition Using MobileNetV2 and FaceNet Deep-Learning Implementations on a Raspberry Pi-400. *Journal of Low Power Electronics and Applications*, 14(3).
<https://doi.org/10.3390/jlpea14030046>
- Nayanathara Thathsarani Pilapitiya, P. G. C., & Ratnayake, A. S. (2024). The world of plastic waste: A review. In *Cleaner Materials* (Vol. 11). Elsevier Ltd.
<https://doi.org/10.1016/j.clema.2024.100220>
- Pučnik, R., Dokl, M., Fan, Y. Van, Vujanović, A., Novak Pintarič, Z., Aviso, K. B., Tan, R. R., Pahor, B., Kravanja, Z., & Čuček, L. (2024). A waste separation system based on sensor technology and deep learning: A simple approach applied to a case study of plastic packaging waste. *Journal of Cleaner Production*, 450.
<https://doi.org/10.1016/j.jclepro.2024.141762>
- Rahman, M. W., Islam, R., Hasan, A., Bithi, N. I., Hasan, M. M., & Rahman, M. M. (2022). Intelligent waste management system using deep learning with IoT. *Journal of King Saud University - Computer and Information Sciences*, 34(5), 2072–2087.
<https://doi.org/10.1016/j.jksuci.2020.08.016>
- Rayhan, Y., & Rifai, A. P. (2024). Multi-class Waste Classification Using Convolutional Neural Network. *Applied Environmental Research*, 46(2).
<https://doi.org/10.35762/AER.2024021>
- Sarker, I. H. (2021). Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, 2, 420.
<https://doi.org/10.1007/s42979-021-00815-1>
- Single, S., Iranmanesh, S., & Raad, R. (2023). RealWaste: A Novel Real-Life Data Set for

- Landfill Waste Classification Using Deep Learning. *Information (Switzerland)*, 14(12). <https://doi.org/10.3390/info14120633>
- Yang, Z., Xia, Z., Yang, G., & Lv, Y. (2022). A Garbage Classification Method Based on a Small Convolution Neural Network. *Sustainability (Switzerland)*, 14(22). <https://doi.org/10.3390/su142214735>
- Yong, L., Ma, L., Sun, D., & Du, L. (2023). Application of MobileNetV2 to waste classification. *PLoS ONE*, 18(3 March). <https://doi.org/10.1371/journal.pone.0282336>