E-ISSN : 2962-9713
P-ISSN : 2963-928X

Analisis Generalisasi Model Klasifikasi Sampah: Komparasi Vision Transformer Dan Convolutional Neural Network Ringan Pada Data Foto Lapangan

Marliana Sinaga[1], Aghna Soelistiawati[2], Irma Yanti Tumanggor[3], Waeisul Bismi[4], Imam Budiawan[5], Nila Hardi[6]

[1]Program Studi Informatika, Universitas Bina Sarana Informatika, 15240543@bsi.ac.id
[2]Program Studi Informatika, Universitas Bina Sarana Informatika, 15240474@bsi.ac.id
[3]Program Studi Informatika, Universitas Bina Sarana Informatika, 15240100@bsi.ac.id
[4]Program Studi Informatika, Universitas Bina Sarana Informatika, Waeisul.wbn@bsi.ac.id
[5]Program Studi Informatika, Universitas Bina Sarana Informatika, imam.imb@bsi.ac.id
[6]Program Studi Informatika, Universitas Bina Sarana Informatika, nila.nad@bsi.ac.id

Abstrak

Model klasifikasi sampah umumnya dilaporkan akurat pada data uji yang berasal dari dataset yang sama dengan data latih, tetapi belum jelas apakah akurasi itu bertahan pada foto di lingkungan sehari-hari. Penelitian ini membandingkan Vision Transformer (ViT-B/16) dan Convolutional Neural Network ringan (MobileNetV3-Large) pada klasifikasi sampah sembilan kelas. Kedua model dilatih dengan transfer learning pada dataset RealWaste (4.752 citra), masing-masing tiga kali dengan acak berbeda, lalu diuji pada data uji dan pada 134 foto lapangan yang diambil sendiri dengan kamera ponsel. Pada data uji, ViT-B/16 mencapai akurasi 90,1% ± 0,7 dan MobileNetV3-Large 89,1% ± 1,2 tanpa perbedaan bermakna (uji McNemar, $p > 0,05$), padahal MobileNetV3-Large sekitar 20 kali lebih kecil dan 21 kali alebih cepat pada CPU. Pada foto lapangan, akurasi turun menjadi 42,8% ± 8,6 (ViT-B/16) dan 41,8% ± 5,2 (MobileNetV3-Large), dan keyakinan model tetap tinggi saat salah. Hasil ini menunjukkan bahwa akurasi pada data uji tidak mencerminkan kinerja di lingkungan nyata, dan model yang jauh lebih kecil dapat dipilih untuk aplikasi seluler tanpa kehilangan akurasi pada data uji.

Kata Kunci: *klasifikasi sampah, generalisasi, Vision Transformer, MobileNetV3, foto lapangan*

Abstract

Waste classification models are often reported to be accurate on test data drawn from the same dataset as the training data, but it is unclear whether this accuracy holds on everyday photographs. This study compares a Vision Transformer (ViT-B/16) and a lightweight Convolutional Neural Network (MobileNetV3-Large) for nine-class waste classification. Both models were fine-tuned by transfer learning on the RealWaste dataset (4,752 images), three times each with different random seeds, and evaluated on the held-out test set and on 134 field photographs taken by the authors with smartphone cameras. On the test set, ViT-B/16 reached 90.1% ± 0.7 accuracy and MobileNetV3-Large 89.1% ± 1.2, with no significant difference (McNemar test, $p > 0.05$), although MobileNetV3-Large is about 20 times smaller and about 21 times faster on a single CPU thread. On field photographs, accuracy dropped to 42.8% ± 8.6 (ViT-B/16) and 41.8% ± 5.2 (MobileNetV3-Large), and model confidence remained high when predictions were wrong. These findings indicate that test-set accuracy does not reflect performance in real environments, and that a much smaller model can be chosen for mobile applications without losing test-set accuracy.

Keywords: *waste classification, generalization, Vision Transformer, MobileNetV3, field photographs*

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Corresponding Author:
Marliana Sinaga
Universitas Bina Sarana Informatika, 15240543@bsi.ac.id

PENDAHULUAN

Pemilahan sampah merupakan tahap penting dalam pengelolaan sampah, dan pengenalan citra berbasis kecerdasan buatan terus dikembangkan untuk mengotomatiskannya, baik pada sistem industri maupun pada aplikasi seluler, termasuk untuk bank sampah (Aprillani dkk., 2024; Yong dkk., 2023). Tinjauan sistematis menunjukkan bahwa model pembelajaran mendalam dan model hibrida mendominasi bidang ini, dengan *Convolutional Neural Network* (CNN) dan *transfer learning* sebagai pendekatan yang paling menjanjikan (Fotovvatikhah dkk., 2025; Putra dan Septiani Putri, 2026).

Arsitektur ringan, terutama keluarga MobileNet, banyak dipakai karena efisien untuk perangkat seluler. Penelitian terdahulu melaporkan akurasi tinggi pada data yang terkontrol, misalnya 98,47% pada klasifikasi biner sampah organik dan non-organik (Oktayaessofa dkk., 2024) dan 98% pada tiga kategori setelah penyetelan *hyperparameter* (Kuncoro dkk., 2025). Pada tugas dengan kelas lebih banyak, akurasinya lebih rendah, misalnya 87,31% (Thio dan Susilo, 2025) dan 82,92% (Yong dkk., 2023). *Vision Transformer* (ViT) juga muncul dalam literatur, tetapi dalam tinjauan sistematis yang dirujuk, penggunaannya berada di bawah CNN, ResNet, MobileNet, EfficientNet, dan YOLO (Putra dan Septiani Putri, 2026).

Meskipun akurasinya tinggi, sebagian besar studi mengevaluasi model pada data uji yang berasal dari dataset yang sama dengan data latih. Sebagian studi yang ditinjau secara eksplisit tidak menguji pada data lapangan (Malik dkk., 2022; Kuncoro dkk., 2025). Tinjauan sistematis mencatat bahwa dataset klasifikasi sampah cenderung tidak seimbang, kurang mewakili kondisi nyata, dan belum terstandar, serta penerapan di lingkungan yang tidak terkontrol masih jarang diteliti (Fotovvatikhah dkk., 2025). Dataset dari fasilitas pemilahan industri yang nyata disebut menjadi tantangan berat bagi model visi komputer mutakhir (Thielmann dkk., 2025). Syarif dkk. (2025) menambahkan foto lingkungan sekitar, tetapi hanya untuk dua kelas dengan dataset kecil. Single dkk. (2023) memperkenalkan RealWaste, dataset foto sampah dari tempat pembuangan akhir, dan melaporkan bahwa model yang dilatih pada dataset lain hanya mencapai akurasi maksimal 49,69% pada kondisi nyata, sedangkan InceptionV3 yang dilatih pada RealWaste mencapai 89,19%.

Penelitian Terdahulu

Pada klasifikasi berbasis CNN, Shi dkk. (2021) mengusulkan CNN hibrida berlapis pada TrashNet (2.527 citra, enam kelas) dengan akurasi 92,6%, dan Malik dkk. (2022) menerapkan *transfer learning* EfficientNet-B0 pada dataset Kaggle yang dipetakan ke sepuluh kelas dengan efisiensi hitung sekitar empat kali lebih baik daripada EfficientNet-B3. Yong dkk. (2023) membandingkan MobileNetV2 dengan CNN sederhana pada lebih dari 80.000 citra (akurasi 82,92% berbanding sekitar 67,5%) dan memasangnya sebagai mini program WeChat, tetapi mencatat bahwa sampah yang rusak, kotor, atau berubah bentuk sulit diklasifikasi. Thio dan Susilo (2025) menemukan MobileNetV2 (87,31%) mengungguli EfficientNetB0 (82,21%), sedangkan Satria Hendrawan dan Hermanto (2026) menemukan varian MobileNetV4 Small dan Medium

E-ISSN : 2962-9713
P-ISSN : 2963-928X

(81%) mengungguli varian Large (74%) yang mengalami *overfitting*. Hasil-hasil ini menunjukkan bahwa model yang lebih besar tidak selalu lebih baik.

Pada aplikasi seluler, Aprillani dkk. (2024) membandingkan MobileNetV2 SSD dan YOLOv8 untuk aplikasi bank sampah dan merekomendasikan YOLOv8 (mAP 0,834), dengan cakupan terbatas pada sampah anorganik. Fadli Setiawan (2025) memakai MobileNetV2 dengan antarmuka Streamlit untuk prediksi *real-time* pada klasifikasi grade sampah plastik dan kaleng, dan Rifaldy dkk. (2025) melaporkan kesulitan membedakan kelas yang mirip seperti logam dan kertas. Dalam studi yang ditinjau, tidak ada yang melaporkan uji pada foto lapangan yang diambil sendiri.

Dalam studi yang ditinjau, peneliti tidak menemukan penelitian yang membandingkan ViT dan CNN ringan pada foto sampah yang diambil sendiri dalam kehidupan sehari-hari. Karena itu belum jelas apakah model dengan akurasi tinggi pada data uji tetap bekerja pada foto semacam itu, dan apakah model yang jauh lebih kecil mengalami penurunan yang sama dengan model yang besar. Penelitian ini bertujuan menjawab tiga pertanyaan: (1) seberapa akurat MobileNetV3-Large dan ViT-B/16 pada data uji dari dataset yang sama dengan data latih; (2) seberapa besar penurunan akurasi keduanya pada foto lapangan; dan (3) apakah ada perbedaan yang bermakna antara kedua model. Kontribusi penelitian ini adalah evaluasi generalisasi dengan foto lapangan yang dikumpulkan dan dicatat secara sistematis, komparasi kedua model dengan tiga pengulangan acak dan uji McNemar, serta pengukuran ukuran dan kecepatan model.

METODE

Dataset

Data latih, validasi, dan uji berasal dari dataset RealWaste (Single dkk., 2023), yaitu foto sampah berukuran 524×524 piksel dalam sembilan kelas dari tempat pembuangan akhir di Wollongong, Australia. Salinan yang digunakan berisi 4.752 citra, sedangkan artikel sumber melaporkan 4.808 citra. Jumlah citra per kelas adalah Gelas (kaca) 420, Kardus 461, Kertas 500, Logam 790, Makanan Organik 411, Plastik 921, Sampah Campur Aduk 495, Sampah Tekstil 318, dan Vegetasi 436. Data dibagi berstrata per kelas menjadi 70% latih, 15% validasi, dan 15% uji dengan acak tetap (*seed* 42), yaitu 3.323, 712, dan 717 citra.

Pra-pemrosesan dan Augmentasi

Citra diubah ke ukuran 224×224 dan dinormalisasi dengan rata-rata dan simpangan baku ImageNet. Augmentasi hanya diterapkan pada data latih, yaitu pemotongan acak (skala 0,7 sampai 1,0), pembalikan horizontal, dan rotasi hingga 15 derajat. Data validasi dan uji hanya diubah ukurannya.

Model dan Pelatihan

Dua model dibandingkan: MobileNetV3-Large (4,2 juta parameter) dan ViT-B/16 (85,8 juta parameter). Keduanya diinisialisasi dengan bobot ImageNet dari pustaka torchvision, lapisan klasifikasi terakhir diganti menjadi sembilan keluaran, dan seluruh bobot dilatih ulang (*fine-tuning*). Pelatihan memakai *optimizer* AdamW, fungsi *loss cross-entropy*, ukuran *batch* 32, dan 8 *epoch*, dengan kecepatan belajar 3×10^{-4} untuk MobileNetV3-Large dan 1×10^{-4} untuk ViT-B/16. Bobot dari *epoch* dengan akurasi validasi tertinggi dipakai untuk pengujian. Setiap model dilatih tiga kali dengan acak berbeda (*seed* 1, 2, dan 3). Pelatihan dijalankan di Google Colab dengan GPU NVIDIA Tesla T4.

Data Foto Lapangan

Foto lapangan diambil oleh anggota peneliti dengan kamera ponsel biasa tanpa filter, di rumah dan lingkungan sekitar. Protokol menetapkan sekitar 20 foto per kelas

E-ISSN : 2962-9713
P-ISSN : 2963-928X

dari benda yang berbeda, dengan satu jenis bahan per foto (kecuali kelas Sampah Campur Aduk yang berisi beberapa jenis bahan), dan foto hanya dipakai untuk menguji, bukan untuk melatih atau menyetel model. Sebanyak 134 foto yang terkumpul pada tahap pertama dianalisis: Gelas 7, Kardus 19, Kertas 11, Logam 19, Makanan Organik 20, Plastik 20, Sampah Campur Aduk 13, Sampah Tekstil 12, dan Vegetasi 13. Foto diproses dengan sisi pendek diubah menjadi 224 piksel lalu dipotong di tengah ke 224×224. Berdasarkan catatan foto, sebagian besar foto diambil pada pencahayaan terang dan jarak dekat, dengan latar yang beragam seperti lantai semen, tegel, tanah, dan di dalam kantong sampah. Label kelas diberikan oleh pengambil foto. Kesepakatan label diperiksa dengan meminta dua pemeriksa melabeli ulang foto secara terpisah tanpa melihat label awal maupun hasil model.

Metrik dan Uji Statistik

Kinerja diukur dengan akurasi dan *macro* F1, dilaporkan sebagai rata-rata dan simpangan baku dari tiga pengulangan. Perbedaan kedua model diuji dengan uji McNemar eksak per pengulangan pada citra yang sama. Selang kepercayaan 95% untuk akurasi foto lapangan dihitung dengan metode Wilson dari rata-rata ketiga pengulangan sebagai perkiraan kasar. Ukuran model diukur dari jumlah parameter dan ukuran berkas, dan kecepatan diukur sebagai waktu prediksi satu citra pada GPU serta pada CPU satu thread di Colab.

HASIL DAN PEMBAHASAN

Kinerja pada Data Uji

Tabel 1 menunjukkan kinerja pada 717 citra data uji. ViT-B/16 mencapai akurasi rata-rata 90,1% dan MobileNetV3-Large 89,1%. Uji McNemar pada tiga pengulangan memberi p = 0,461; 0,822; dan 0,314, sehingga tidak ada perbedaan yang bermakna. Kedua model memberi jawaban berbeda pada sekitar 11 sampai 13% citra uji (79 sampai 90 dari 717 citra), meskipun akurasinya setara. Akurasi ini sejalan dengan Single dkk. (2023) yang melaporkan 89,19% untuk InceptionV3 pada RealWaste.

Tabel 1 : Kinerja pada data uji (rata-rata ± simpangan baku, tiga pengulangan)

Model	Akurasi	Macro F1
MobileNetV3-Large	89,1% ± 1,2	0,897 ± 0,014
ViT-B/16	90,1% ± 0,7	0,901 ± 0,007

Kesetaraan ini sejalan dengan temuan lain bahwa model yang lebih besar tidak selalu unggul (Thio dan Susilo, 2025; Satria Hendrawan dan Hermanto, 2026). Dugaan peneliti, dataset berukuran menengah (sekitar 3.300 citra latih) dengan bobot awal dari ImageNet tidak cukup membedakan kapasitas kedua model; dugaan ini belum diuji. Pada satu pengulangan, kesalahan terbanyak MobileNetV3-Large adalah logam yang dibaca plastik (7 citra) dan kardus yang dibaca kertas (6 citra); pada ViT-B/16 kesalahan kardus dan kertas hampir hilang, tetapi logam yang dibaca plastik bertambah menjadi 11 citra. Tertukarnya kardus, kertas, plastik, dan logam juga dilaporkan oleh Single dkk. (2023).

Ukuran dan Kecepatan

MobileNetV3-Large sekitar 20 kali lebih kecil daripada ViT-B/16. Pada GPU, ViT-B/16 sekitar 2,2 kali lebih lambat, sedangkan pada CPU satu thread selisihnya sekitar 21 kali (Tabel 2). Angka CPU diperoleh di lingkungan Colab, sehingga perbandingannya lebih bermakna daripada nilai absolutnya.

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Tabel 2 : Ukuran dan kecepatan model

Ukuran	MobileNetV3-Large	ViT-B/16
Parameter	4,2 juta	85,8 juta
Ukuran berkas	17,1 MB	343,3 MB
Waktu per citra, GPU T4	5,9 sampai 6,6 ms	13,3 sampai 14,7 ms
Waktu per citra, CPU satu thread	22 ms	465 ms
Waktu pelatihan	sekitar 197 detik (satu kali jalan)	sekitar 1.000 detik

Kinerja pada Foto Lapangan

Akurasi turun tajam pada foto lapangan, dari sekitar 90% pada data uji menjadi sekitar 42% untuk kedua model (Tabel 3 dan Gambar 1). Penurunannya sama besar, yaitu sekitar 47 poin, dan kedua model tidak dapat dibedakan. Variasi antar pengulangan besar, terutama pada ViT-B/16 (34,3% sampai 51,5%). Arah penurunan ini sejalan dengan laporan Single dkk. (2023) bahwa model yang dilatih pada dataset lain hanya mencapai akurasi maksimal 49,69% pada kondisi nyata, dan dengan catatan bahwa dataset klasifikasi sampah kurang mewakili kondisi nyata (Fotovvatikhah dkk., 2025).

Tabel 3 : Akurasi pada 134 foto lapangan (label dari pengambil foto)

Model	Akurasi rata-rata	SD antar pengulangan	Selang kepercayaan 95% (perkiraan)
MobileNetV3-Large	41,8%	5,2	33,8% sampai 50,3%
ViT-B/16	42,8%	8,6	34,7% sampai 51,2%

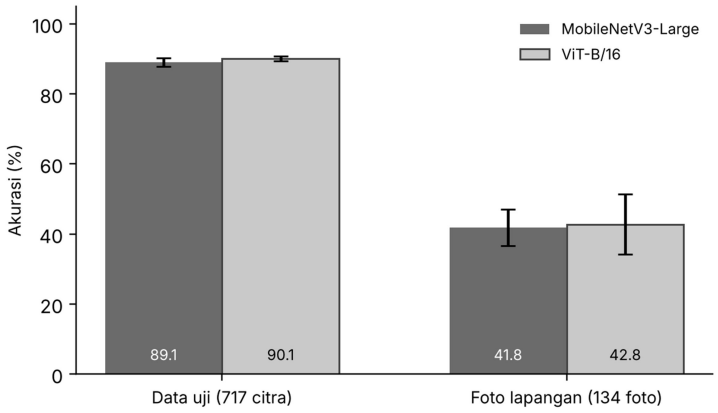

Gambar 1 : Akurasi pada data uji dan pada foto lapangan (rata-rata ± simpangan baku, tiga pengulangan)

Dugaan peneliti, foto latih bersifat seragam (satu benda, dilihat dari atas, latar polos di tempat pembuangan), sedangkan foto lapangan memiliki latar yang beragam, benda yang kotor atau basah, dan sebagian berupa kelompok benda. Karena pencahayaan dan jarak hampir seragam pada foto lapangan (sebagian besar terang dan dekat), pengaruh keduanya tidak dapat dianalisis.

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Pola Kesalahan per Kelas

Tabel 4 : Akurasi per kelas pada foto lapangan (rata-rata tiga pengulangan)

Kelas	Jumlah foto	MobileNetV3-Large	ViT-B/16
Kardus	19	66,7%	71,9%
Makanan Organik	20	65,0%	56,7%
Kertas	11	51,5%	60,6%
Sampah Tekstil	12	52,8%	47,2%
Vegetasi	13	51,3%	38,5%
Logam	19	38,6%	43,9%
Plastik	20	20,0%	25,0%
Gelas	7	0,0%	14,3%
Sampah Campur Aduk	13	2,6%	5,1%

Plastik hanya mencapai 20% sampai 25% pada foto lapangan, padahal kelas ini memiliki data latih terbanyak. Dugaan peneliti, plastik adalah bahan dan bukan satu bentuk benda: kantong, kemasan fleksibel, dan botol bening terlihat sangat berbeda, dan sebagian mirip kelas lain. Kesulitan pada kelas yang mirip juga dilaporkan oleh Rifaldy dkk. (2025) untuk logam dan kertas, dan oleh Yong dkk. (2023) untuk sampah yang rusak atau kotor. Jumlah foto kelas Gelas dan Kertas kecil, sehingga angka per kelasnya tidak boleh ditafsirkan terlalu jauh.

Akurasi kelas Sampah Campur Aduk yang hampir nol perlu ditafsirkan hati-hati. Berdasarkan catatan benda pada tabel foto, sebagian foto berlabel Sampah Campur Aduk berisi satu jenis bahan, misalnya sisa makanan atau tumpukan kardus, yang tidak sesuai dengan definisi beberapa jenis bahan dalam satu foto. Jika kelas ini dikeluarkan dari perhitungan, akurasi rata-rata naik menjadi sekitar 46% untuk kedua model (dihitung dari akurasi per kelas), sehingga penurunan dari data uji tetap besar. Single dkk. (2023) juga melaporkan bahwa kelas sampah campur (*miscellaneous trash*) paling sulit, dengan akurasi sekitar 74% pada data mereka.

Keyakinan Model dan Kesepakatan Pemeriksa

Rata-rata keyakinan model pada foto lapangan tetap tinggi saat salah, yaitu 72,7% untuk MobileNetV3-Large dan 67,2% untuk ViT-B/16, dibandingkan 82,5% dan 75,8% saat benar. Keyakinan keluaran *softmax* karena itu tidak dapat dijadikan tanda bahwa sebuah foto berada di luar kemampuan model, dan aplikasi yang memakainya memerlukan mekanisme peringatan yang tidak hanya bertumpu pada angka tersebut. Dua pemeriksa yang melabeli ulang 134 foto secara terpisah sepakat pada 76,9% foto (kappa Cohen 0,738), dan berbeda pendapat pada 31 foto. Artinya sebagian foto lapangan memang ambigu bagi manusia, sehingga akurasi model pada foto lapangan sebaiknya dibaca bersama tingkat kesepakatan ini.

Implikasi untuk Aplikasi Seluler

MobileNetV3-Large berukuran 17,1 MB dan sekitar 21 kali lebih cepat pada CPU, dengan akurasi data uji yang sebanding dengan ViT-B/16. Karena itu model ini lebih sesuai untuk aplikasi seluler dan bank sampah (Aprillani dkk., 2024; Yong dkk., 2023). Namun akurasi lapangan yang rendah menunjukkan bahwa penerapan nyata

E-ISSN : 2962-9713
P-ISSN : 2963-928X

memerlukan data dari lingkungan pengguna dan peringatan bagi pengguna ketika hasil tidak meyakinkan.

Keterbatasan

Penelitian ini memakai satu dataset dan satu pembagian data, tiga pengulangan, dan 134 foto lapangan dengan jumlah kecil pada beberapa kelas. Pencahayaan dan jarak foto hampir seragam, label diberikan oleh pengambil foto, dan sebagian label kelas Sampah Campur Aduk tidak konsisten dengan definisinya. Setiap foto hanya memiliki satu label sehingga foto berisi banyak benda berada di luar cakupan. Pengaturan pelatihan tidak dituning secara intensif, dan waktu diukur di Colab, bukan di ponsel. Foto tambahan yang dikumpulkan setelah tahap pertama belum dianalisis.

SIMPULAN

Pada data uji dari dataset yang sama dengan data latih, ViT-B/16 dan MobileNetV3-Large mencapai akurasi yang sebanding (90,1% dan 89,1%) tanpa perbedaan bermakna, padahal MobileNetV3-Large sekitar 20 kali lebih kecil dan 21 kali lebih cepat pada CPU. Pada 134 foto lapangan, akurasi keduanya turun menjadi sekitar 42%, dan keyakinan model tetap tinggi saat salah. Akurasi pada data uji karena itu tidak mencerminkan kinerja di lingkungan nyata, dan penurunannya tidak berbeda antara model besar dan model ringan.

Penelitian lanjutan dapat menambah dan memverifikasi foto lapangan dengan variasi pencahayaan dan jarak, melatih ulang model dengan data lapangan, mengkalibrasi keyakinan model, dan memakai deteksi objek agar setiap benda dalam satu foto dikenali.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pengampu mata kuliah atas bimbingan, dan kepada Universitas Bina Sarana Informatika atas dukungan selama penelitian ini.

DAFTAR PUSTAKA

Aprillani, S., Baqir, F. Y., Zaini, I. N., Hertiana, S. N., & Sussi, S. (2024). Advanced Waste Detection: Mobilenetv2 SSD and Yolov8 for Waste Bank Mobile Application. *2024 IEEE International Conference on Control & Automation, Electronics, Robotics, Internet of Things, and Artificial Intelligence (CERIA)*, 1–5. https://doi.org/10.1109/CERIA64726.2024.10914827

Fadli Setiawan, M. (2025). IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) PADA KLASIFIKASI GRADE JENIS SAMPAH PLASTIK DAN KALENG. *Jurnal Informatika Dan Teknik Elektro Terapan*, *13*(3S1). https://doi.org/10.23960/jitet.v13i3S1.7805

Fotovvatikhah, F., Ahmedy, I., Noor, R. M., & Munir, M. U. (2025). A Systematic Review of AI-Based Techniques for Automated Waste Classification. *Sensors*, *25*(10), 3181. https://doi.org/10.3390/s25103181

Kuncoro, D. F., Wirasto, A., & Triwibowo, D. N. (2025). Klasifikasi Jenis Sampah Berbasis Convolutional Neural Network dengan Optimasi Hyperparameter Tuning Arsitektur Mobilenet. *METHOMIKA Jurnal Manajemen Informatika Dan Komputerisasi Akuntansi*, *9*(1), 130–144. https://doi.org/10.46880/jmika.Vol9No1.pp130-144

Malik, M., Sharma, S., Uddin, M., Chen, C.-L., Wu, C.-M., Soni, P., & Chaudhary, S. (2022). Waste Classification for Sustainable Development Using Image

E-ISSN : 2962-9713
P-ISSN : 2963-928X

Recognition with Deep Learning Neural Network Models. *Sustainability*, *14*(12), 7222. https://doi.org/10.3390/su14127222

Oktayaessofa, E., Sari, C. A., Rachmawanto, E. H., & Yaacob, N. M. (2024). CLASSIFICATION OF ORGANIC AND NON-ORGANIC WASTE WITH CNN-MOBILENET-V2. *Jurnal Teknik Informatika (Jutif)*, *5*(4), 1173–1180. https://doi.org/10.52436/1.jutif.2024.5.4.2165

Putra, E. D., & Septiani Putri, A. (2026). Systematic Literature Review terhadap Model Deep Learning untuk Smart Waste Classification. *JUKOMIKA (Jurnal Ilmu Komputer Dan Informatika)*, *9*(1), 56–65. https://doi.org/10.54650/jukomika.v9i1.715

Rifaldy, F., Prayoga, M. I., & Harahap, L. S. (2025). PENGEMBANGAN SISTEM KLASIFIKASI SAMPAH UNTUK DAUR ULANG OTOMATIS BERBASIS CITRA MENGGUNAKAN MODEL CNN. *Melek IT : Information Technology Journal*, *11*(1), 11–20. https://doi.org/10.30742/melekitjournal.v11i1.397

Satria Hendrawan, P., & Hermanto, D. (2026). KLASIFIKASI SAMPAH MENGGUNAKAN CNN DENGAN ARSITEKTUR MOBILENETV4 DAN TRANSFER LEARNING. *JATI (Jurnal Mahasiswa Teknik Informatika)*, *10*(4), 7337–7343. https://doi.org/10.36040/jati.v10i4.19534

Shi, C., Tan, C., Wang, T., & Wang, L. (2021). A Waste Classification Method Based on a Multilayer Hybrid Convolution Neural Network. *Applied Sciences*, *11*(18), 8572. https://doi.org/10.3390/app11188572

Single, S., Iranmanesh, S., & Raad, R. (2023). RealWaste: A Novel Real-Life Data Set for Landfill Waste Classification Using Deep Learning. *Information*, *14*(12), 633. https://doi.org/10.3390/info14120633

Syarif, M., Prasetyo, S., Oktaviana Az Zahra, E., Indra Kristiawan, Y., & Dwi Irawan, R. (2025). Klasifikasi Sampah Organik dan Anorganik Menggunakan Transfer Learning MobileNetV2 pada Citra Digital. *Prosiding Seminar Nasional Teknologi Informasi Dan Bisnis*, 1028–1033. https://doi.org/10.47701/wabtd264

Thielmann, P., Zhou, Y., Mirbach, B., Stricker, D., & Rambach, J. (2025). A Review of Computer Vision for Industrial-Grade Waste Classification. *IEEE Access*, *13*, 151934–151953. https://doi.org/10.1109/ACCESS.2025.3603903

Thio, S. E., & Susilo, J. (2025). Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0. *Bit-Tech*, *8*(1), 25–32. https://doi.org/10.32877/bt.v8i1.1900

Yong, L., Ma, L., Sun, D., & Du, L. (2023). Application of MobileNetV2 to waste classification. *PLOS ONE*, *18*(3), e0282336. https://doi.org/10.1371/journal.pone.0282336