

Performance Evaluation of MobileNetV2 and DenseNet169 Using Transfer Learning for Inorganic Waste Image Classification

Ari wibowo¹, Erwin Dwika Putra^{2*}, Sastya Hendri Wibowo³, Ardi Wijaya⁴

^{1,2,3,4}Program Studi Informatika, Fakultas Teknik, Universitas Muhammadiyah Bengkulu, Indonesia

¹ariwibowo14kph@gmail.com ; ²erwindwikap@gmail.com ; ³Sastiahendriwibowo@gmail.com; ⁴ardiwijaya@umb.ac.id ;

Abstrak.

Tujuan : Pemilahan sampah secara manual masih memiliki keterbatasan karena membutuhkan waktu yang lama serta berpotensi mengalami kesalahan dalam proses identifikasi jenis sampah. Perkembangan teknologi *Computer Vision* dan *Deep Learning* memberikan peluang untuk membangun sistem klasifikasi citra sampah secara otomatis. Penelitian ini bertujuan untuk membandingkan performa dua arsitektur *Convolutional Neural Network* (CNN), yaitu MobileNetV2 dan DenseNet169, dalam melakukan klasifikasi citra sampah anorganik berbasis *Transfer Learning*.

Metode/Design/Pendekatan: Penelitian ini menggunakan metode *Transfer Learning* dengan memanfaatkan arsitektur MobileNetV2 dan DenseNet169. Dataset yang digunakan terdiri dari citra sampah anorganik kategori *cardboard* dan *paper* yang diperoleh dari dataset Kaggle serta data primer hasil dokumentasi penelitian. Tahapan penelitian meliputi pengumpulan dataset, *preprocessing* citra, pembagian dataset menjadi data *training*, *validation*, dan *testing*, proses pelatihan model, serta evaluasi menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Confusion Matrix*. Dataset dibagi dengan proporsi 80% data *training*, 10% data *validation*, dan 10% data *testing*.

Hasil/Temuan: Hasil penelitian menunjukkan bahwa MobileNetV2 memperoleh nilai *Accuracy* sebesar 96,14%, *Precision* 95,05%, *Recall* 97,82%, dan *F1-Score* 96,42%. Sementara itu, DenseNet169 memperoleh *Accuracy* sebesar 96,14%, *Precision* 95,70%, *Recall* 97,09%, dan *F1-Score* 96,39%.

Kebaharuan/Originalitas/Nilai: Penelitian ini memberikan analisis perbandingan objektif antara model ringan MobileNetV2 dan model dengan kompleksitas lebih tinggi DenseNet169 menggunakan konfigurasi eksperimen yang sama. Hasil menunjukkan bahwa MobileNetV2 mampu memberikan performa klasifikasi yang setara dengan DenseNet169 dengan kebutuhan parameter dan komputasi yang lebih rendah, sehingga lebih sesuai untuk implementasi pada perangkat dengan sumber daya terbatas.

Keywords: Transfer Learning, Deep Learning, MobileNetV2, DenseNet169, Computer Vision, Image Classification

Abstract.

Purpose: Manual waste sorting still has limitations because it requires considerable time and may cause errors in identifying waste categories. The development of *Computer Vision* and *Deep Learning* technology provides an opportunity to develop an automated waste image classification system. This study aims to compare the performance of two *Convolutional Neural Network* (CNN) architectures, namely MobileNetV2 and DenseNet169, for inorganic waste image classification using the *Transfer Learning* approach.

Methods/Study design/approach: This study applies a *Transfer Learning* method using MobileNetV2 and DenseNet169 architectures. The dataset consists of inorganic waste images from two categories, namely *cardboard* and *paper*, obtained from the Kaggle dataset and primary documentation data. The research stages include dataset collection, image preprocessing, dataset splitting, model training, and performance evaluation using *Accuracy*, *Precision*, *Recall*, *F1-Score*, and *Confusion Matrix*. The dataset was divided into 80% training data, 10% validation data, and 10% testing data.

Result/Findings: The experimental results show that MobileNetV2 achieved an *Accuracy* of 96.14%, *Precision* of 95.05%, *Recall* of 97.82%, and *F1-Score* of 96.42%. Meanwhile, DenseNet169 achieved an *Accuracy* of 96.14%, *Precision* of 95.70%, *Recall* of 97.09%, and *F1-Score* of 96.39%.

Novelty/Originality/Value: This study provides an objective comparison between a lightweight CNN architecture (MobileNetV2) and a deeper architecture (DenseNet169) using the same experimental configuration. The results indicate that MobileNetV2 can achieve comparable classification performance with lower computational complexity, making it more suitable for implementation on resource-constrained devices.

Keywords: Transfer Learning, Deep Learning, MobileNetV2, DenseNet169, Computer Vision, Image Classification

Article history:

Received, 2026-08-22

Revised, 2026-09-22

Accepted, 2026-10-06

*Corresponding author.

Erwin Dwika Putra

Email addresses: erwindwikap@gmail.com

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

PENDAHULUAN

Pengelolaan sampah merupakan salah satu permasalahan lingkungan yang terus mengalami peningkatan seiring dengan pertumbuhan populasi dan aktivitas manusia. Peningkatan jumlah sampah menyebabkan kebutuhan terhadap sistem pengelolaan yang efektif, terutama dalam proses pemilahan sampah berdasarkan jenisnya. Sampah anorganik seperti kertas (*paper*) dan kardus (*cardboard*) memiliki nilai ekonomi yang dapat dimanfaatkan kembali melalui proses daur ulang. Namun, proses pemilahan yang masih dilakukan secara manual memiliki beberapa keterbatasan, seperti membutuhkan waktu yang relatif lama, bergantung pada kemampuan manusia, serta memiliki kemungkinan terjadi kesalahan dalam proses identifikasi jenis sampah.[1], [2]

Perkembangan teknologi *Artificial Intelligence* (AI), khususnya bidang *Computer Vision* dan *Deep Learning*, memberikan peluang untuk mengembangkan sistem klasifikasi citra secara otomatis[3]. Metode berbasis *Deep Learning* telah banyak diterapkan dalam berbagai bidang pengenalan objek karena mampu melakukan ekstraksi fitur secara otomatis dari data citra tanpa memerlukan proses rekayasa fitur secara manual[4]. Salah satu metode yang banyak digunakan dalam klasifikasi citra adalah *Convolutional Neural Network* (CNN), yang memiliki kemampuan dalam mengenali pola visual melalui proses pembelajaran berlapis (*deep feature extraction*) [4], [5].

Dalam penerapannya, pembangunan model *Deep Learning* dengan dataset yang besar membutuhkan sumber daya komputasi yang tinggi. Oleh karena itu, pendekatan *Transfer Learning* banyak digunakan untuk memanfaatkan model yang telah dilatih sebelumnya (*pre-trained model*) sehingga proses pelatihan dapat dilakukan secara lebih efisien. *Transfer Learning* memungkinkan pengetahuan dari model yang telah dilatih pada dataset besar untuk diterapkan pada permasalahan baru dengan jumlah data yang lebih terbatas [6], [7].


Beberapa arsitektur CNN yang banyak digunakan dalam klasifikasi citra adalah MobileNetV2 dan DenseNet169[8]. MobileNetV2 merupakan arsitektur yang dirancang untuk perangkat dengan keterbatasan sumber daya melalui penggunaan *depthwise separable convolution* dan struktur *inverted residual block*, sehingga memiliki jumlah parameter yang lebih rendah dibandingkan arsitektur CNN konvensional[9], [10]. Sementara itu, DenseNet169 menggunakan konsep *dense connectivity*, yaitu setiap lapisan terhubung dengan lapisan sebelumnya sehingga memungkinkan penggunaan kembali fitur (*feature reuse*) dan meningkatkan kemampuan ekstraksi informasi dari citra [11], [12].

Penelitian sebelumnya menunjukkan bahwa kedua arsitektur tersebut memiliki kemampuan yang baik dalam berbagai tugas klasifikasi citra[13], [14]. Namun, perbandingan langsung antara model ringan seperti MobileNetV2 dan model dengan struktur lebih kompleks seperti DenseNet169 pada kondisi eksperimen yang sama masih perlu dikaji. Perbedaan jumlah parameter, kompleksitas model, dan kebutuhan komputasi dapat mempengaruhi pemilihan arsitektur untuk implementasi pada sistem klasifikasi berbasis perangkat terbatas.[15], [16]

Berdasarkan permasalahan tersebut, penelitian ini melakukan perbandingan performa arsitektur MobileNetV2 dan DenseNet169 untuk klasifikasi citra sampah anorganik menggunakan pendekatan *Transfer Learning*. Dataset yang digunakan terdiri dari kategori *cardboard* dan *paper*. Kedua model diuji menggunakan konfigurasi eksperimen yang sama dengan evaluasi berdasarkan *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Confusion Matrix*. Penelitian ini diharapkan dapat memberikan informasi mengenai model yang memiliki keseimbangan terbaik antara performa klasifikasi dan efisiensi komputasi sehingga dapat mendukung pengembangan sistem pemilahan sampah otomatis.

METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen dengan pendekatan *Transfer Learning* untuk membandingkan performa dua arsitektur *Convolutional Neural Network* (CNN), yaitu MobileNetV2 dan DenseNet169 dalam melakukan klasifikasi citra sampah anorganik. Penelitian dilakukan melalui beberapa tahapan yang meliputi identifikasi masalah, studi literatur, pengumpulan dataset, preprocessing data, pelaksanaan eksperimen, pelatihan model, evaluasi model, perbandingan performa kedua model, serta penentuan model terbaik. Tahapan penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Tahap pertama penelitian adalah identifikasi masalah yang dilakukan dengan mengkaji permasalahan pada proses pemilahan sampah anorganik. Proses pemilahan secara manual masih memiliki keterbatasan karena membutuhkan waktu yang relatif lama serta bergantung pada kemampuan manusia dalam mengenali jenis sampah. Permasalahan tersebut menjadi dasar penerapan teknologi *Computer Vision* dan *Deep Learning* untuk membangun sistem klasifikasi citra sampah secara otomatis.

Tahap selanjutnya adalah studi literatur yang dilakukan untuk memperoleh referensi terkait metode klasifikasi citra berbasis *Deep Learning*, khususnya penggunaan arsitektur CNN dan pendekatan *Transfer Learning*. Studi literatur digunakan sebagai dasar dalam menentukan metode penelitian, pemilihan arsitektur MobileNetV2 dan DenseNet169, serta parameter eksperimen yang digunakan dalam proses pelatihan model. Tahap pengumpulan dataset dilakukan dengan mengumpulkan citra sampah anorganik yang digunakan sebagai data penelitian. Dataset yang digunakan terdiri dari dua kategori sampah, yaitu *cardboard* dan *paper*. Dataset diperoleh dari sumber dataset publik Kaggle serta data primer hasil dokumentasi penelitian. Data yang telah dikumpulkan kemudian digunakan sebagai masukan dalam proses pelatihan dan pengujian model klasifikasi.

Sebelum dilakukan proses pelatihan model, dataset melalui tahap *preprocessing* data untuk menyesuaikan karakteristik citra dengan kebutuhan model CNN. Tahapan *preprocessing* meliputi perubahan ukuran citra (*resize*) menjadi 224×224 piksel, normalisasi nilai piksel ke rentang 0 hingga 1, serta penerapan *data augmentation* untuk meningkatkan variasi data pelatihan. Teknik augmentasi digunakan untuk membantu model mengenali variasi citra dan mengurangi risiko *overfitting*. Dataset kemudian dibagi menjadi tiga bagian, yaitu data *training* sebesar 80%, data *validation* sebesar 10%, dan data *testing* sebesar 10%. Pembagian dataset tersebut diterapkan secara sama pada kedua model agar proses perbandingan performa berlangsung secara objektif.

Tabel 1. Pembagian Dataset Penelitian

Dataset	Persentase
Training	80%
Validation	10%
Testing	10%

Tahap pelaksanaan eksperimen dilakukan dengan menerapkan dua arsitektur CNN berbasis *Transfer Learning*, yaitu MobileNetV2 dan DenseNet169. MobileNetV2 digunakan sebagai model pertama karena memiliki karakteristik arsitektur ringan dengan efisiensi komputasi yang baik. Sementara itu, DenseNet169 digunakan sebagai model pembandingan karena memiliki struktur jaringan yang lebih dalam dengan mekanisme *dense connectivity* yang memungkinkan penggunaan kembali fitur dari lapisan sebelumnya.

Kedua model menggunakan konfigurasi eksperimen yang sama untuk memastikan perbandingan dilakukan secara adil. Proses pelatihan model dilakukan menggunakan parameter yang telah ditentukan, yaitu ukuran input citra 224×224 piksel, *optimizer* Adam, *learning rate* 0,00001, *batch size* 32, dan jumlah *epoch* sebanyak 30. Implementasi model dilakukan menggunakan framework TensorFlow dan Keras pada lingkungan Google Colaboratory.

Tabel 2. Konfigurasi Eksperimen

Parameter	Nilai
Input Image Size	224×224 pixel
Optimizer	Adam
Learning Rate	0,00001
Batch Size	32
Epoch	30
Framework	TensorFlow dan Keras

Setelah proses pelatihan selesai, tahap evaluasi model dilakukan untuk mengetahui kemampuan MobileNetV2 dan DenseNet169 dalam melakukan klasifikasi citra sampah anorganik. Evaluasi dilakukan menggunakan data *testing* dengan beberapa metrik pengukuran, yaitu *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Confusion Matrix*. Penggunaan beberapa metrik tersebut bertujuan untuk memperoleh gambaran performa model secara menyeluruh, tidak hanya berdasarkan tingkat akurasi, tetapi juga kemampuan model dalam mengenali setiap kelas sampah.


Tahap akhir penelitian dilakukan dengan melakukan perbandingan kedua model berdasarkan hasil evaluasi performa dan efisiensi komputasi. Perbandingan tersebut digunakan untuk menentukan model yang memiliki performa klasifikasi terbaik serta keseimbangan antara akurasi dan kebutuhan sumber daya komputasi. Hasil akhir penelitian digunakan sebagai dasar dalam menentukan arsitektur yang paling sesuai untuk implementasi sistem klasifikasi citra sampah anorganik.

HASIL DAN PEMBAHASAN

Hasil Pengujian Model MobileNetV2

Tahap pengujian dilakukan untuk mengetahui kemampuan model MobileNetV2 dalam melakukan klasifikasi citra sampah anorganik berdasarkan dataset pengujian. Evaluasi model dilakukan menggunakan beberapa metrik, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Selain itu, *Confusion Matrix* digunakan untuk mengetahui distribusi hasil prediksi benar dan kesalahan klasifikasi pada masing-masing kelas.

Berdasarkan hasil pengujian, MobileNetV2 mampu melakukan klasifikasi citra sampah anorganik dengan performa yang sangat baik. Model mampu mengenali pola visual pada dua kelas sampah yang digunakan, yaitu *cardboard* dan *paper*. Kemampuan tersebut menunjukkan bahwa penggunaan metode *Transfer Learning* pada MobileNetV2 mampu membantu model dalam melakukan ekstraksi fitur citra secara efektif.



Gambar 2. Confusion Matrix MobileNetV2

Berdasarkan hasil *Confusion Matrix* MobileNetV2, sebagian besar citra pada data pengujian berhasil diklasifikasikan dengan benar. Kesalahan klasifikasi yang terjadi relatif kecil, sehingga menunjukkan bahwa model mampu membedakan karakteristik visual antara kelas *cardboard* dan *paper* dengan baik. Hasil evaluasi MobileNetV2 ditampilkan pada Tabel 3.


Tabel 3. Classification Report MobileNetV2

Kelas	Precision	Recall	F1-Score	Support
Cardboard	0,97	0,94	0,96	243
Paper	0,95	0,98	0,96	275
Accuracy	0,9614			518

Berdasarkan hasil pengujian, MobileNetV2 memperoleh nilai *Accuracy* sebesar 96,14%, *Precision* sebesar 95,05%, *Recall* sebesar 97,82%, dan *F1-Score* sebesar 96,42%. Nilai tersebut menunjukkan bahwa MobileNetV2 mampu melakukan klasifikasi dengan tingkat ketepatan yang tinggi pada data pengujian.

Hasil Pengujian Model DenseNet169

Pengujian berikutnya dilakukan terhadap model DenseNet169 menggunakan dataset pengujian yang sama. Sama seperti MobileNetV2, evaluasi dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, serta analisis *Confusion Matrix*.



Gambar 3. Confusion Matrix DenseNet169

Berdasarkan hasil *Confusion Matrix*, DenseNet169 mampu mengklasifikasikan sebagian besar citra dengan benar. Kesalahan prediksi yang terjadi relatif sedikit, menunjukkan bahwa DenseNet169 memiliki kemampuan ekstraksi fitur yang baik dalam membedakan karakteristik visual antara kelas *cardboard* dan *paper*. Hasil *Classification Report* DenseNet169 ditunjukkan pada Tabel 4.

Tabel 4. Classification Report DenseNet169

Kelas	Precision	Recall	F1-Score
Cardboard	0,97	0,95	0,96
Paper	0,96	0,97	0,96
Accuracy	-	-	96,14%

Berdasarkan Tabel 4, DenseNet169 memperoleh nilai *Accuracy* sebesar 96,14%, *Precision* sebesar 95,70%, *Recall* sebesar 97,09%, dan *F1-Score* sebesar 96,39%. Hasil tersebut menunjukkan bahwa DenseNet169 mampu memberikan performa klasifikasi yang seimbang pada kedua kelas sampah anorganik. Pada kelas *cardboard*, model memperoleh *Precision* sebesar 97% dan *Recall* sebesar 95%, sedangkan pada kelas *paper* memperoleh *Precision* sebesar 96% dan *Recall* sebesar 97%.

Perbandingan Performa MobileNetV2 dan DenseNet169

Setelah proses pelatihan dan pengujian kedua model selesai dilakukan, tahap selanjutnya adalah membandingkan performa MobileNetV2 dan DenseNet169 berdasarkan metrik evaluasi serta jumlah parameter model. Perbandingan dilakukan menggunakan dataset pengujian yang sama untuk memperoleh hasil evaluasi yang objektif.

Tabel 5. Perbandingan Performa MobileNetV2 dan DenseNet169

Model	Accuracy	Precision	Recall	F1-Score	Jumlah Parameter
MobileNetV2	96,14%	95,05%	97,82%	96,42%	±2,6 juta
DenseNet169	96,14%	95,70%	97,09%	96,39%	±12,6 juta

Berdasarkan Tabel 5, kedua model menghasilkan nilai *Accuracy* yang sama yaitu sebesar 96,14%. Hasil tersebut menunjukkan bahwa MobileNetV2 dan DenseNet169 memiliki kemampuan yang sama baik dalam mempelajari karakteristik visual citra sampah anorganik melalui pendekatan *Transfer Learning*.

Meskipun memiliki nilai *Accuracy* yang sama, terdapat perbedaan pada metrik evaluasi lainnya. DenseNet169 memperoleh nilai *Precision* sebesar 95,70%, lebih tinggi dibandingkan MobileNetV2 sebesar 95,05%. Hal ini menunjukkan bahwa DenseNet169 memiliki kemampuan sedikit lebih baik dalam menghasilkan prediksi positif yang tepat.

Di sisi lain, MobileNetV2 memiliki nilai *Recall* sebesar 97,82%, lebih tinggi dibandingkan DenseNet169 sebesar 97,09%. Hal tersebut menunjukkan bahwa MobileNetV2 memiliki kemampuan lebih baik dalam mengenali keseluruhan data dari kelas yang tersedia.

Selain performa klasifikasi, penelitian ini juga mempertimbangkan aspek efisiensi komputasi melalui jumlah parameter model. MobileNetV2 hanya menggunakan sekitar 2,6 juta parameter, sedangkan DenseNet169 menggunakan sekitar 12,6 juta parameter. Perbedaan jumlah parameter tersebut menunjukkan bahwa MobileNetV2 memiliki struktur yang lebih ringan sehingga lebih sesuai untuk diterapkan pada perangkat dengan keterbatasan sumber daya.

Analisis Hasil Penelitian

Hasil penelitian menunjukkan bahwa peningkatan kompleksitas arsitektur tidak selalu menghasilkan peningkatan performa klasifikasi yang signifikan. DenseNet169 memiliki struktur jaringan yang lebih kompleks dengan jumlah parameter lebih besar, tetapi tidak memberikan peningkatan *Accuracy* dibandingkan MobileNetV2.

MobileNetV2 mampu memberikan performa klasifikasi yang setara dengan DenseNet169 dengan kebutuhan komputasi yang lebih rendah. Hal tersebut menjadi keunggulan penting terutama untuk implementasi sistem klasifikasi sampah berbasis perangkat ringan (*edge device*) yang memiliki keterbatasan memori dan kemampuan komputasi. Dengan mempertimbangkan keseimbangan antara performa dan efisiensi, MobileNetV2 menjadi model yang lebih optimal untuk diterapkan pada sistem klasifikasi citra sampah anorganik secara praktis.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *Transfer Learning* menggunakan arsitektur MobileNetV2 dan DenseNet169 mampu melakukan klasifikasi citra sampah anorganik dengan performa yang sangat baik. Penelitian ini berhasil menjawab tujuan utama yaitu membandingkan kemampuan kedua arsitektur dalam mengenali citra sampah kategori *cardboard* dan *paper* berdasarkan metrik evaluasi *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Hasil pengujian menunjukkan bahwa MobileNetV2 dan DenseNet169 memperoleh nilai *Accuracy* yang sama, yaitu sebesar 96,14%. MobileNetV2 memperoleh nilai *Precision* 95,05%, *Recall* 97,82%, dan *F1-Score* 96,42%, sedangkan DenseNet169 memperoleh nilai *Precision* 95,70%, *Recall* 97,09%, dan *F1-Score* 96,39%. Meskipun memiliki performa klasifikasi yang hampir setara, MobileNetV2 memiliki keunggulan dari sisi efisiensi komputasi karena menggunakan jumlah parameter yang lebih rendah dibandingkan DenseNet169. Berdasarkan hasil tersebut, MobileNetV2 dapat menjadi pilihan yang lebih optimal untuk implementasi sistem klasifikasi sampah otomatis, terutama pada perangkat dengan keterbatasan sumber daya komputasi. Penelitian selanjutnya dapat dikembangkan dengan menambahkan variasi kelas sampah yang lebih banyak, menggunakan dataset dengan jumlah citra yang lebih besar, serta melakukan pengujian implementasi pada perangkat nyata seperti *mobile device* atau sistem *edge computing* untuk mengetahui kemampuan model dalam kondisi penggunaan sebenarnya.

REFERENSI

- [1] G. Ahmad *et al.*, "Intelligent waste sorting for urban sustainability using deep learning," *Sci. Rep.*, vol. 15, no. 1, pp. 1–19, 2025, doi: 10.1038/s41598-025-08461-w.
- [2] M. F. Setiawan and A. H. Rismawiyana, "Implementasi Algoritma Convolutional Neural Network (CNN) pada Klasifikasi Grade Jenis Sampah Plastik dan Kaleng," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 3S1, pp. 729–737, Oct. 2025, doi: 10.23960/jitet.v13i3S1.7805.
- [3] J. J. C. Simbolon, Robet, and Hendri, "Household Waste Image Classification Using Deep Learning Model," *J. Artif. Intell. Eng. Appl.*, vol. 5, no. 1, pp. 1681–1690, Oct. 2025, doi: 10.59934/jaiea.v5i1.1690.
- [4] Y. Chu, C. Huang, X. Xie, B. Tan, S. Kamal, and X. Xiong, "Multilayer hybrid deep-learning method for waste classification and recycling," *Comput. Intell. Neurosci.*, vol. 2018, 2018, doi: 10.1155/2018/5060857.
- [5] M. F. Setiawan, A. H. Rismawiyana, P. T. Informatika, C. Utara, and K. Cimahi, "IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) PADA KLASIFIKASI GRADE JENIS

- SAMPAH PLASTIK DAN KALENG,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.*, vol. 13, no. 3, 2024.
- [6] Doly Ilham Saputra Huta Julu and Dewi Nurdiah, “Klasifikasi Sampah Organik Dan Non Organik Menggunakan Transfer Learning,” *J. Transform.*, vol. 23, no. 1, pp. 12–29, 2025, doi: 10.26623/transformatika.v23i1.12201.
- [7] S. E. Thio and J. Susilo, “Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0,” *bit-Tech*, vol. 8, no. 1, pp. 25–32, 2025, doi: 10.32877/bt.v8i1.1900.
- [8] S. Agustiani, H. Haryani, A. Junaidi, R. R. Putri, and M. G. Adam Z, “Comparative Optimization of EfficientNetB3, MobileNetV2, and ResNet50 for Waste Classification,” *J. Inform.*, vol. 12, no. 2, pp. 131–137, Oct. 2025, doi: 10.31294/inf.v12i2.27533.
- [9] R. A. Kumala, C. A. Sari, and E. H. Rachmawanto, “A Comparison of MobileNetV2 and VGG16 Architectures with Transfer Learning for Multi-Class Image-Based Waste Classification,” *J. Appl. Informatics Comput.*, vol. 9, no. 4, pp. 1610–1624, 2025, doi: 10.30871/jaic.v9i4.9958.
- [10] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.
- [11] M. E. Purba, A. Z. Situmorang, G. L. Br Ginting, M. W. P. Lubis, and F. M. Sinaga, “Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN,” *J. Sifo Mikroskil*, vol. 26, no. 1, pp. 37–54, 2025, doi: 10.55601/jsm.v26i1.1510.
- [12] A. N. Bakti and N. H. Shabrina, “Plastic Waste Identification using ResNet-50: A Deep Learning Approach,” *Rekayasa*, vol. 17, no. 3, pp. 380–386, 2024, doi: 10.21107/rekayasa.v17i3.26456.
- [13] P. Komputasi *et al.*, “Studi Perbandingan Penggunaan Konvolusional Model Jaringan Saraf Tiruan dalam Klasifikasi Limbah,” 2025.
- [14] P. O. Parasian and F. Utaminingrum, “Rancang Bangun Sistem Pengklasifikasi Jenis Sampah Organik dan Sampah Daur Ulang menggunakan Resnet50,” *J. Pengemb. Teknol. ...*, vol. 6, no. 4, pp. 2548–964, 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [15] N. Azzahra, “Perbandingan Performa Klasifikasi Gambar Sampah Antara Mobilenetv2 Dan Densenet169,” 2024.
- [16] E. Oktayaessofa, C. A. Sari, E. H. Rachmawanto, and N. M. Yaacob, “Classification of Organic and Non-Organic Waste With Cnn-Mobilenet-V2,” *J. Tek. Inform.*, vol. 5, no. 4, pp. 1173–1180, 2024, doi: 10.52436/1.jutif.2024.5.4.2165.