

Analisis *Robustness* Model *Deep Learning* pada Klasifikasi Sampah Non-Organik terhadap Variasi Pencahayaan dan *Noise* Citra

¹Erwin Dwika Putra, ²Marissa Utami

^{1,2}Fakultas Teknik, Universitas Muhammadiyah Bengkulu, Indonesia

¹erwindwikap@gmail.com; ²marissautami@umb.ac.id;

Article Info

Article history:

Received, 2026-06-17

Revised, 2026-06-20

Accepted, 2026-06-27

Kata Kunci:

deep learning,
klasifikasi sampah,
robustness,
pencahayaan,
Gaussian noise,
TACO dataset.

Keywords:

deep learning,
waste classification,
robustness,
illumination variation,
Gaussian noise,
TACO dataset.

ABSTRAK

Peningkatan jumlah sampah non-organik menimbulkan tantangan dalam proses pengelolaan dan pemilahan sampah secara efektif. Teknologi *deep learning* telah banyak digunakan untuk klasifikasi sampah berbasis citra, namun sebagian besar penelitian masih berfokus pada peningkatan akurasi model pada kondisi ideal dan belum memperhatikan ketahanan model terhadap gangguan visual di lingkungan nyata. Penelitian ini bertujuan untuk menganalisis *robustness* model *deep learning* pada klasifikasi sampah non-organik terhadap variasi pencahayaan dan *noise* citra menggunakan dataset publik TACO (*Trash Annotation in Context*). Tiga model yang digunakan yaitu *EfficientNet-B0*, *ResNet50*, dan *MobileNetV2*. Pengujian dilakukan dengan memberikan variasi *brightness* dan *Gaussian Noise* pada beberapa tingkat gangguan. Hasil penelitian menunjukkan bahwa *EfficientNet-B0* menghasilkan performa terbaik dengan nilai *accuracy* sebesar 87,84%, *precision* sebesar 87,17%, *recall* sebesar 85,35%, dan *F1-score* sebesar 85,39%. Selain itu, *EfficientNet-B0* juga memperoleh nilai *robustness* tertinggi sebesar 0,823 dibandingkan *ResNet50* dan *MobileNetV2*. Hasil penelitian menunjukkan bahwa variasi pencahayaan dan *noise* memengaruhi performa model, terutama pada tingkat gangguan visual yang tinggi.

ABSTRACT

The increasing amount of non-organic waste presents challenges in effective waste management and sorting processes. Deep learning technology has been widely used for image-based waste classification; however, most previous studies mainly focused on improving model accuracy under ideal conditions without considering model robustness against visual disturbances in real-world environments. This study aims to analyze the robustness of deep learning models for non-organic waste classification under illumination variations and image noise using the public TACO (*Trash Annotations in Context*) dataset. Three deep learning models were employed, namely *EfficientNet-B0*, *ResNet50*, and *MobileNetV2*. The experiments were conducted by applying multiple brightness levels and *Gaussian noise* disturbances. The results showed that *EfficientNet-B0* achieved the best performance with an accuracy of 87.84%, precision of 87.17%, recall of 85.35%, and *F1-score* of 85.39%. Furthermore, *EfficientNet-B0* obtained the highest robustness score of 0.823 compared to *ResNet50* and *MobileNetV2*. The findings indicate that illumination variations and image noise significantly affect model performance, especially under severe visual disturbances.

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



Penulis Korespondensi:

Erwin Dwika Putra,
Program Studi Informatika,
Universitas Muhammadiyah Bengkulu,
Email: erwindwikap@gmail.com

1. PENDAHULUAN

Peningkatan jumlah sampah global menjadi salah satu tantangan lingkungan yang semakin kompleks seiring bertambahnya populasi, urbanisasi, serta aktivitas industri dan rumah tangga. Pengelolaan sampah yang tidak optimal dapat menyebabkan pencemaran lingkungan, gangguan kesehatan masyarakat, serta menurunkan kualitas ekosistem. Salah satu tahapan penting dalam pengelolaan sampah adalah proses pemilahan berdasarkan jenis material agar proses daur ulang dapat dilakukan secara efektif. Proses pemilahan secara manual masih memiliki berbagai keterbatasan seperti ketergantungan terhadap tenaga manusia, waktu operasional yang tinggi, serta tingginya kemungkinan terjadinya kesalahan identifikasi [1], [2]. Penelitian sebelumnya menunjukkan bahwa sistem otomatis berbasis pengolahan citra dapat menjadi solusi untuk meningkatkan efisiensi proses pemilahan sampah.

Perkembangan teknologi *Artificial Intelligence* (AI), khususnya *Deep Learning*, telah memberikan kontribusi besar dalam bidang pengolahan citra digital. Berbagai arsitektur seperti *Convolutional Neural Network* (CNN), *ResNet*, *EfficientNet*, *Vision Transformer*, hingga *ConvNeXt* telah menunjukkan performa yang sangat baik dalam berbagai tugas klasifikasi citra [3], [4]. Pada klasifikasi sampah berbasis citra, pendekatan *deep learning* mampu mengekstraksi karakteristik visual seperti warna, tekstur, bentuk, dan pola objek secara otomatis tanpa memerlukan ekstraksi fitur manual [5]. Sejumlah penelitian melaporkan tingkat akurasi yang tinggi pada klasifikasi sampah menggunakan berbagai model *deep learning*. Model *SwinConvNeXt* yang menggabungkan mekanisme transformer dan *ConvNeXt* mampu mencapai akurasi sebesar 98,97% pada dataset klasifikasi sampah [6]. Selain itu, penggunaan *ConvNeXt* sebagai *backbone* pada sistem klasifikasi sampah juga menghasilkan performa yang lebih baik dibandingkan beberapa model konvensional [7].

Meskipun berbagai penelitian menunjukkan performa yang tinggi, sebagian besar penelitian terdahulu lebih berfokus pada peningkatan akurasi model dalam kondisi citra yang ideal [8]. Pada implementasi nyata, sistem klasifikasi sampah sering menghadapi berbagai kondisi lingkungan yang tidak terkontrol, seperti perubahan pencahayaan, bayangan, kualitas sensor kamera, sudut pengambilan gambar, dan gangguan *noise* citra [9]. Kondisi tersebut menyebabkan karakteristik visual objek mengalami perubahan sehingga dapat menurunkan kemampuan model dalam mengenali objek secara konsisten [10]. Variasi pencahayaan dapat menyebabkan perubahan distribusi intensitas piksel, menurunkan kontras citra, dan menghilangkan informasi visual penting yang dibutuhkan model untuk proses klasifikasi [11].

Penelitian terkait klasifikasi sampah pada kondisi pencahayaan rendah menunjukkan bahwa model yang memiliki akurasi tinggi pada kondisi normal belum tentu mampu mempertahankan performa pada lingkungan dengan pencahayaan yang berbeda [12]. Qiao et al. mengembangkan model *Dark-Waste* berbasis *ConvNeXt* untuk mengatasi permasalahan klasifikasi sampah pada skenario *low illumination*. Hasil penelitian tersebut menunjukkan bahwa kondisi pencahayaan rendah menyebabkan menurunnya diskriminasi objek sehingga meningkatkan kesalahan klasifikasi [1]. Penelitian lain juga menunjukkan bahwa perubahan kondisi pencahayaan dapat memengaruhi kemampuan ekstraksi fitur CNN secara signifikan [13].

Selain faktor pencahayaan, *noise* citra juga menjadi salah satu permasalahan yang sering muncul dalam sistem pengolahan citra dunia nyata. *Noise* dapat muncul akibat keterbatasan perangkat sensor kamera, proses transmisi data, kondisi lingkungan, maupun gangguan elektromagnetik. Jenis *noise* yang umum dijumpai pada citra digital antara lain *Gaussian Noise*, *Salt-and-Pepper Noise*, dan *Speckle Noise*. Keberadaan *noise* dapat mengubah pola visual citra dan mengganggu proses ekstraksi fitur yang dilakukan oleh model *deep learning* [14]. Penelitian sebelumnya menunjukkan bahwa penambahan skenario gangguan visual melalui *noise-assisted* data enhancement dapat meningkatkan generalisasi model dan meningkatkan ketahanan model terhadap kondisi lingkungan nyata [2].

Konsep *robustness* menjadi salah satu aspek penting dalam pengembangan sistem berbasis *deep learning*. *Robustness* menggambarkan kemampuan model untuk mempertahankan performa ketika menerima data yang mengalami gangguan atau perubahan distribusi dibandingkan data pelatihan [15]. Model dengan akurasi tinggi pada data bersih belum tentu memiliki kemampuan generalisasi yang baik ketika dihadapkan pada variasi kondisi dunia nyata [16]. Permasalahan ini menjadi penting karena sistem klasifikasi sampah umumnya diterapkan pada lingkungan terbuka yang memiliki kondisi pencahayaan dan kualitas citra yang sangat bervariasi [17].

Berdasarkan tinjauan penelitian sebelumnya, sebagian besar penelitian klasifikasi sampah masih berfokus pada peningkatan akurasi model melalui modifikasi arsitektur atau optimasi parameter model [18]. Penelitian yang secara khusus menganalisis ketahanan model terhadap variasi pencahayaan dan gangguan *noise* masih relatif terbatas [19]. Padahal, kemampuan model dalam menghadapi variasi visual sangat menentukan keberhasilan implementasi sistem pada kondisi nyata [20]. Dengan demikian, diperlukan penelitian yang tidak hanya

mengevaluasi performa model pada data normal, tetapi juga menguji stabilitas model ketika dihadapkan pada gangguan visual yang realistis.

Penelitian ini bertujuan untuk menganalisis robustness model deep learning pada klasifikasi sampah non-organik terhadap variasi pencahayaan dan noise citra. Variasi pencahayaan dilakukan melalui perubahan tingkat intensitas cahaya pada citra, sedangkan gangguan noise diterapkan menggunakan beberapa skenario seperti Gaussian Noise dan Salt-and-Pepper Noise. Evaluasi dilakukan menggunakan metrik accuracy, precision, recall, F1-score, dan tingkat degradasi performa model. Novelty penelitian ini terletak pada analisis ketahanan model terhadap kondisi visual yang menyerupai lingkungan nyata sehingga tidak hanya berorientasi pada peningkatan akurasi model, tetapi juga pada kemampuan generalisasi dan stabilitas model terhadap perubahan lingkungan visual.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimen (*experimental research*) untuk menganalisis tingkat robustness model *deep learning* pada klasifikasi sampah non-organik terhadap variasi pencahayaan dan *noise* citra. Penelitian dilakukan dengan memberikan berbagai skenario gangguan visual pada citra masukan kemudian mengevaluasi kemampuan model dalam mempertahankan performanya. Fokus penelitian tidak hanya pada tingkat akurasi model pada kondisi citra normal, tetapi juga pada kemampuan model dalam melakukan generalisasi ketika menghadapi kondisi lingkungan yang tidak ideal seperti perubahan pencahayaan dan adanya gangguan visual. Tahapan penelitian dilakukan secara sistematis mulai dari pengumpulan *dataset* hingga analisis *robustness model*.



Gambar 1 Alur Penelitian

Tahap pertama penelitian dimulai dengan proses pengumpulan dataset. Penelitian menggunakan dataset publik TACO (*Trash Annotation in Context*) karena memiliki karakteristik yang sesuai dengan kebutuhan penelitian, yaitu berisi citra sampah pada lingkungan nyata dengan variasi kondisi pengambilan gambar yang beragam. Dari dataset tersebut dipilih beberapa kategori sampah non-organik seperti plastik, kaleng, kaca, kardus, logam, dan kertas. Pemilihan kategori dilakukan agar objek penelitian lebih spesifik dan sesuai dengan tujuan klasifikasi sampah non-organik. Selanjutnya dataset dibagi menjadi tiga bagian menggunakan metode stratified sampling agar distribusi setiap kelas tetap seimbang, yaitu data pelatihan sebesar 70%, data validasi sebesar 15%, dan data pengujian sebesar 15%.

Tahap kedua merupakan proses *preprocessing* atau prapemrosesan data yang bertujuan untuk menyeragamkan kualitas citra sebelum dilakukan proses pelatihan model. Pada tahap ini seluruh citra diubah ukurannya (*resize*) menjadi resolusi 224×224 piksel agar sesuai dengan kebutuhan input model *deep learning*. Setelah proses perubahan ukuran, dilakukan normalisasi nilai piksel ke rentang 0–1 menggunakan persamaan:

$$x' = \frac{x}{255} \quad (1)$$

dengan x merupakan nilai piksel awal dan x' merupakan nilai piksel hasil normalisasi. Proses normalisasi dilakukan untuk mempercepat konvergensi model selama pelatihan dan mengurangi perbedaan distribusi data.

Setelah proses prapemrosesan selesai, dilakukan tahap data augmentation untuk meningkatkan variasi data pelatihan dan mengurangi potensi *overfitting*. Teknik augmentasi yang digunakan meliputi rotasi sebesar $\pm 20^\circ$, *horizontal flip*, *zoom*, *shift*, dan *shear transformation*. Tahapan ini dilakukan agar model dapat mempelajari karakteristik objek dari berbagai kondisi dan posisi sehingga kemampuan generalisasi model menjadi lebih baik.

Tahap berikutnya merupakan tahapan utama dalam penelitian, yaitu pembentukan skenario gangguan visual (*visual perturbation scenario*) untuk menguji tingkat *robustness model*. Gangguan visual yang digunakan terdiri dari variasi pencahayaan dan penambahan *noise* citra. Variasi pencahayaan dilakukan dengan memodifikasi intensitas citra menggunakan persamaan:

$$I' = \alpha I \quad (2)$$

dengan I merupakan citra awal, I' merupakan citra hasil perubahan, dan α merupakan faktor perubahan intensitas. Nilai faktor intensitas yang digunakan meliputi 0,5; 0,7; 1,0; 1,3; dan 1,5 yang mewakili kondisi gelap hingga terang. Variasi ini digunakan untuk mensimulasikan kondisi lingkungan nyata seperti pencahayaan rendah, bayangan, dan pencahayaan berlebih. Selain variasi pencahayaan, dilakukan penambahan *noise* pada citra menggunakan dua jenis *noise*, yaitu *Gaussian Noise* dan *Salt-and-Pepper Noise*. *Gaussian Noise* ditambahkan menggunakan persamaan:

$$I_n = I + N(0, \sigma^2) \quad (3)$$

dengan I_n merupakan citra yang telah diberikan *noise*, sedangkan σ merupakan standar deviasi distribusi *Gaussian*. Nilai standar deviasi yang digunakan yaitu 0,05; 0,10; 0,20; dan 0,30. Sementara itu, *Salt-and-Pepper Noise* diterapkan menggunakan tingkat density sebesar 0,01; 0,03; 0,05; dan 0,10. Kedua jenis *noise* tersebut dipilih karena umum ditemukan pada sistem pengambilan citra digital.

Tahap selanjutnya adalah proses pelatihan model *deep learning*. Pada penelitian ini digunakan tiga model yaitu *EfficientNet-B0*, *ResNet50*, dan *MobileNetV2*. Pemilihan ketiga model tersebut didasarkan pada karakteristik arsitektur yang berbeda sehingga dapat memberikan gambaran perbandingan tingkat *robustness* masing-masing model. *EfficientNet-B0* dipilih karena memiliki keseimbangan antara kompleksitas model dan akurasi, *ResNet50* dipilih karena memiliki mekanisme *skip connection* yang efektif dalam mengatasi *vanishing gradient*, sedangkan *MobileNetV2* dipilih karena memiliki kompleksitas komputasi yang rendah dan sesuai untuk implementasi *edge computing*. Proses pelatihan model menggunakan *optimizer Adam* dengan *learning rate* sebesar 0,0001, *batch size* 32, jumlah *epoch* sebanyak 50, serta fungsi *loss categorical crossentropy*.

Setelah proses pelatihan selesai, dilakukan tahap pengujian dan evaluasi model menggunakan data pengujian yang telah diberi berbagai skenario gangguan visual. Evaluasi dilakukan menggunakan beberapa metrik pengukuran yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Penggunaan beberapa metrik evaluasi dilakukan agar kinerja model dapat dianalisis secara lebih komprehensif dan tidak hanya bergantung pada satu indikator performa. Tahap terakhir adalah analisis *robustness model*. Tingkat *robustness* dihitung berdasarkan perubahan performa model antara kondisi normal dan kondisi yang telah mengalami gangguan visual menggunakan persamaan:

$$Robustness = 1 - \frac{Acc_{normal} - Acc_{perturbation}}{Acc_{normal}} \quad (4)$$

Berdasarkan persamaan diatas dimana Acc_{normal} merupakan akurasi model pada data normal dan $Acc_{perturbation}$ merupakan akurasi model pada data yang telah mengalami gangguan. Nilai *robustness* yang tinggi menunjukkan bahwa model mampu mempertahankan performa meskipun mengalami perubahan kondisi visual. Hasil evaluasi kemudian dianalisis menggunakan grafik perubahan performa, *confusion matrix*, dan pengujian statistik untuk mengetahui pengaruh variasi pencahayaan serta *noise* terhadap tingkat ketahanan model *deep learning* pada klasifikasi sampah non-organik.

3. HASIL DAN ANALISIS

Hasil penelitian menunjukkan bahwa performa model *deep learning* pada proses klasifikasi sampah non-organik dipengaruhi oleh kondisi visual citra yang digunakan sebagai masukan. Pengujian awal dilakukan menggunakan data normal tanpa gangguan visual untuk mengetahui performa dasar dari masing-masing model. Berdasarkan hasil pengujian pada data normal, model *EfficientNet-B0* memperoleh performa tertinggi dengan nilai *accuracy* sebesar 87,84%, *precision* sebesar 87,17%, *recall* sebesar 85,35%, dan *F1-score* sebesar 85,39%. Sementara itu, model *ResNet50* memperoleh *accuracy* sebesar 84,71%, sedangkan *MobileNetV2* menghasilkan *accuracy* sebesar 72,85%. Hasil tersebut menunjukkan bahwa *EfficientNet-B0* memiliki kemampuan yang lebih baik dalam mengekstraksi karakteristik visual objek sampah dibandingkan model lainnya. Hal ini disebabkan *EfficientNet-B0* menerapkan pendekatan *compound scaling* yang menyeimbangkan kedalaman jaringan, lebar jaringan, dan resolusi citra sehingga proses ekstraksi fitur menjadi lebih optimal. Sebaliknya, *MobileNetV2* memiliki kompleksitas model yang lebih ringan sehingga kemampuan ekstraksi fitur yang dihasilkan menjadi lebih terbatas.

Tabel 1. Performa model pada data normal

Model	Accuracy (%)	Precision (%)	Recall (%)	F1-score (%)
<i>EfficientNet-B0</i>	87.84	87.17	85.35	85.39
<i>ResNet50</i>	84.71	84.15	84.12	84.19
<i>MobileNetV2</i>	72.85	72.42	72.64	72.52

Selanjutnya dilakukan pengujian terhadap variasi pencahayaan (*brightness variation*) untuk mengetahui kemampuan model mempertahankan performanya pada kondisi pencahayaan yang berbeda. Hasil pengujian menunjukkan bahwa perubahan tingkat pencahayaan memberikan dampak yang berbeda pada setiap model. Pada kondisi pencahayaan rendah dengan faktor *brightness* sebesar 0,5, *EfficientNet-B0* memperoleh akurasi sebesar 82,62%, *ResNet50* sebesar 72,63%, dan *MobileNetV2* sebesar 69,45%. Ketika tingkat pencahayaan meningkat menjadi kondisi normal hingga terang sedang, terjadi peningkatan performa pada sebagian besar model. *EfficientNet-B0* memperoleh akurasi tertinggi sebesar 87,50% pada faktor pencahayaan 1,3, sedangkan *ResNet50* memperoleh akurasi tertinggi sebesar 84,12% pada kondisi normal. Hasil yang menarik ditemukan pada *MobileNetV2* yang justru memperoleh performa terbaik pada faktor pencahayaan 1,0 dengan akurasi sebesar 88,15%.

Tabel 2. Hasil akurasi terhadap variasi pencahayaan

Brightness	<i>EfficientNet</i>	<i>ResNet50</i>	<i>MobileNetV2</i>
0.5	82.62	72.63	69.45
0.7	83.13	78.42	75.64
1.0	85.14	84.12	88.15
1.3	87.50	81.63	79.30
1.5	79.23	76.85	83.12

Berdasarkan hasil tersebut dapat diketahui bahwa perubahan intensitas pencahayaan memengaruhi kemampuan model dalam mengenali fitur objek. Kondisi pencahayaan rendah menyebabkan menurunnya kontras citra dan hilangnya informasi penting seperti tekstur, bentuk, dan batas objek sehingga proses ekstraksi fitur menjadi kurang optimal. Sementara itu, kondisi pencahayaan yang terlalu tinggi juga dapat menimbulkan *overexposure* sehingga beberapa bagian citra kehilangan detail visual. *EfficientNet-B0* menunjukkan performa yang relatif lebih stabil dibandingkan model lain pada berbagai skenario pencahayaan. Hal ini mengindikasikan bahwa model tersebut memiliki kemampuan adaptasi yang lebih baik terhadap perubahan distribusi visual pada citra.

Pengujian berikutnya dilakukan dengan menambahkan *Gaussian Noise* pada citra untuk mensimulasikan gangguan yang umum terjadi pada proses pengambilan gambar digital. Berdasarkan hasil pengujian, seluruh model mengalami penurunan performa seiring meningkatnya nilai standar deviasi (σ) pada *noise*. Pada nilai $\sigma = 0,05$, *EfficientNet-B0* memperoleh akurasi sebesar 83,41%, *ResNet50* sebesar 81,58%, dan *MobileNetV2* sebesar 79,87%. Ketika tingkat *noise* meningkat menjadi $\sigma = 0,30$, terjadi penurunan akurasi yang cukup signifikan. *EfficientNet-B0* mengalami penurunan menjadi 60,57%, *ResNet50* menjadi 66,81%, sedangkan *MobileNetV2* turun hingga 52,13%.

Tabel 3. Akurasi terhadap *gaussian noise*

σ	<i>EfficientNet</i>	<i>ResNet50</i>	<i>MobileNetV2</i>
0.05	83.41	81.58	79.87
0.10	80.26	78.14	75.55
0.20	75.53	72.42	69.54
0.30	60.57	66.81	52.13

Penurunan performa tersebut menunjukkan bahwa keberadaan *noise* dapat mengganggu proses identifikasi fitur penting pada objek. Semakin tinggi tingkat *noise*, semakin besar kemungkinan perubahan distribusi piksel yang menyebabkan model mengalami kesalahan dalam proses klasifikasi. Menariknya, meskipun *EfficientNet-B0* memiliki akurasi tertinggi pada kondisi normal, *ResNet50* menunjukkan performa yang sedikit lebih baik

pada tingkat noise tinggi dengan $\sigma = 0,30$. Hal tersebut menunjukkan bahwa mekanisme *skip connection* pada *ResNet50* mampu membantu mempertahankan informasi fitur pada kondisi citra yang mengalami degradasi berat.

Tingkat *robustness model* selanjutnya dihitung untuk mengetahui kemampuan model mempertahankan performa ketika menerima gangguan visual. Hasil perhitungan menunjukkan bahwa *EfficientNet-B0* memperoleh nilai *robustness* tertinggi sebesar 0,823, diikuti *ResNet50* sebesar 0,760 dan *MobileNetV2* sebesar 0,711. Nilai tersebut menunjukkan bahwa *EfficientNet-B0* memiliki tingkat ketahanan yang lebih baik dibandingkan model lainnya. Nilai *robustness* yang lebih tinggi menunjukkan bahwa penurunan performa model akibat gangguan visual relatif lebih kecil dibandingkan model lain.

Tabel 4. Nilai *robustness*

Model	Robustness
<i>EfficientNet-B0</i>	0.823
<i>ResNet50</i>	0.760
<i>MobileNetV2</i>	0.711

Selain evaluasi kuantitatif, dilakukan pula analisis visual terhadap hasil prediksi model menggunakan contoh citra dari dataset TACO sebagaimana ditunjukkan pada Gambar 2. Pada gambar menunjukkan contoh kategori sampah non-organik yang digunakan pada penelitian, yaitu plastik, kaleng, dan logam. Sementara itu, pada gambar juga memperlihatkan hasil prediksi model pada kondisi citra normal dan citra yang telah diberikan noise. Pada citra normal, model mampu melakukan prediksi dengan tingkat keyakinan yang tinggi, misalnya objek kaleng berhasil dikenali dengan tingkat prediksi sebesar 100%, sedangkan objek plastik juga berhasil diklasifikasikan dengan akurasi prediksi sebesar 100%. Namun, ketika citra mengalami gangguan noise, terjadi penurunan tingkat keyakinan model. Objek kaleng masih dapat dikenali dengan probabilitas sebesar 87,7%, sedangkan objek plastik mengalami kesalahan klasifikasi dan diprediksi sebagai kaleng dengan tingkat keyakinan sebesar 66,4%.



Gambar 2. Visualisasi dataset dan hasil

Hasil visual tersebut memperkuat hasil evaluasi kuantitatif yang menunjukkan bahwa gangguan visual memengaruhi kemampuan model dalam mengenali karakteristik objek secara konsisten. Penambahan *noise* menyebabkan perubahan tekstur, warna, serta batas objek sehingga fitur yang dipelajari model menjadi kurang representatif. Hal ini mengindikasikan bahwa meskipun model *deep learning* memiliki performa yang baik pada kondisi normal, kemampuan generalisasi terhadap kondisi dunia nyata masih menjadi tantangan yang perlu diperhatikan dalam pengembangan sistem klasifikasi sampah otomatis. Secara keseluruhan, hasil penelitian menunjukkan bahwa *EfficientNet-B0* merupakan model dengan performa dan *robustness* terbaik pada klasifikasi sampah non-organik terhadap variasi pencahayaan dan noise citra. Temuan ini menunjukkan bahwa pemilihan arsitektur model yang tepat berpengaruh signifikan terhadap ketahanan sistem klasifikasi pada kondisi lingkungan yang bervariasi.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa variasi pencahayaan dan *noise* citra memberikan pengaruh signifikan terhadap performa model deep learning dalam klasifikasi sampah non-organik. Pengujian pada tiga model, yaitu *EfficientNet-B0*, *ResNet50*, dan *MobileNetV2* menunjukkan bahwa setiap model memiliki tingkat ketahanan yang berbeda terhadap gangguan visual. *EfficientNet-B0* memperoleh performa terbaik pada data normal dengan nilai *accuracy* sebesar 87,84% dan juga menunjukkan tingkat *robustness* tertinggi sebesar 0,823. Hasil pengujian variasi pencahayaan menunjukkan bahwa perubahan intensitas cahaya dapat menyebabkan penurunan kemampuan model dalam mengekstraksi fitur visual akibat berkurangnya informasi tekstur dan kontras objek. Selain itu, peningkatan tingkat *Gaussian Noise* menyebabkan penurunan performa yang semakin besar pada seluruh model karena adanya perubahan distribusi piksel citra yang memengaruhi proses identifikasi fitur objek. Analisis visual hasil prediksi juga menunjukkan bahwa citra yang mengalami gangguan *noise* berpotensi menghasilkan kesalahan klasifikasi meskipun model memiliki performa yang tinggi pada kondisi normal. Secara keseluruhan, *EfficientNet-B0* menunjukkan kemampuan generalisasi dan stabilitas yang lebih baik dibandingkan model lainnya sehingga memiliki potensi lebih besar untuk diterapkan pada sistem klasifikasi sampah otomatis di lingkungan nyata.

REFERENSI

- [1] Y. Qiao, Q. Zhang, Y. Qi, T. Wan, L. Yang, and X. Yu, "A Waste Classification model in Low-illumination scenes based on ConvNeXt," *Resour. Conserv. Recycl.*, vol. 199, p. 107274, Dec. 2023, doi: 10.1016/j.resconrec.2023.107274.
- [2] C. Chen *et al.*, "Noise-assisted data enhancement promoting image classification of municipal solid waste," *Resour. Conserv. Recycl.*, vol. 209, p. 107790, Oct. 2024, doi: 10.1016/j.resconrec.2024.107790.
- [3] B. Madhavi *et al.*, "SwinConvNeXt: a fused deep learning architecture for Real-time garbage image classification," *Sci. Rep.*, vol. 15, no. 1, p. 7995, Mar. 2025, doi: 10.1038/s41598-025-91302-7.
- [4] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *ICML*, Sep. 2020, [Online]. Available: <http://arxiv.org/abs/1905.11946>
- [5] J. Qi, M. Nguyen, and W. Q. Yan, "Waste Classification from Digital Images Using ConvNeXt," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 13763 LNCS, 2023, pp. 1–13. doi: 10.1007/978-3-031-26431-3_1.
- [6] N.-B.-Q. Nguyen, T.-M. Do, C.-T. Phan, and T.-T.-H. Phan, "Towards Accurate and Efficient Waste Image Classification: A Hybrid Deep Learning and Machine Learning Approach," Oct. 2025, doi: 10.1016/j.asej.2026.104062.
- [7] Z. Chen, Y. Xiao, Q. Zhou, Y. Li, and B. Chen, "The development of a waste management and classification system based on deep learning and Internet of Things," *Environ. Monit. Assess.*, vol. 197, no. 1, p. 103, Dec. 2025, doi: 10.1007/s10661-024-13595-x.
- [8] N. B. Q. Nguyen, T. M. Do, C. T. Phan, and T. T. H. Phan, "Towards accurate and efficient waste image classification: A hybrid deep learning and machine learning approach," *Ain Shams Eng. J.*, vol. 17, no. 4, p. 104062, Apr. 2026, doi: 10.1016/j.asej.2026.104062.
- [9] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," *32nd Int. Conf. Mach. Learn. ICML 2015*, vol. 1, pp. 448–456, Mar. 2015, [Online]. Available: <http://arxiv.org/abs/1502.03167>
- [10] D. Verber, T. Grneva, and J. Dugonik, "Image-Based Waste Classification Using a Hybrid Deep Learning Architecture with Transfer Learning and Edge AI Deployment," *Mathematics*, vol. 14, no. 7, p. 1176, Apr. 2026, doi: 10.3390/math14071176.
- [11] Risfendra, G. F. Ananda, and H. Setyawan, "Deep Learning-Based Waste Classification with Transfer Learning Using EfficientNet-B0 Model," *J. RESTI*, vol. 8, no. 4, pp. 535–541, Aug. 2024, doi: 10.29207/resti.v8i4.5875.
- [12] F. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J. Big Data*, vol. 6, no. 1, p. 60, 2019.
- [13] D. Verber, T. Grneva, and J. Dugonik, "Image-Based Waste Classification Using a Hybrid Deep Learning Architecture with Transfer Learning and Edge AI Deployment," *Mathematics*, vol. 14, no. 7, p. 1176, Apr. 2026, doi: 10.3390/math14071176.

- [14] M. Zulhusni, C. A. Sari, and E. H. Rachmawanto, "Implementation of DenseNet121 Architecture for Waste Type Classification," *Adv. Sustain. Sci. Eng. Technol.*, vol. 6, no. 3, p. 02403015, Jul. 2024, doi: 10.26877/asset.v6i3.673.
- [15] I. K. M. C. Qinantha, I. G. A. Indrawan, I. P. S. U. Putra, I. G. A. A. M. Aristamy, and A. G. Willdahlia, "Classification Of Organic And Inorganic Waste Using Resnet50," *Indones. J. Data Sci.*, vol. 6, no. 2, pp. 232–240, Jul. 2025, doi: 10.56705/ijodas.v6i2.267.
- [16] A. A. Salsabila, "Penerapan Arsitektur Deep Learning EfficientNetB0 Berbasis Citra Digital untuk Meningkatkan Kinerja Sistem Klasifikasi Sampah Organik," *JURIKOM (Jurnal Ris. Komputer)*, vol. 12, no. 6, pp. 1006–1017, Dec. 2025, doi: 10.30865/jurikom.v12i6.9360.
- [17] M. Al Adib *et al.*, "Explainable Deep Learning Framework for Waste Image Classification Using MobileNetv2 with Grad-CAM and SHAP," *J. Komput. Teknol. Inf. Sist. Inf.*, vol. 4, no. 3, pp. 1697–1710, Dec. 2025, doi: 10.62712/juktisi.v4i3.739.
- [18] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J. Big Data*, vol. 8, no. 1, p. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [19] A. Dosovitskiy *et al.*, "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," *ICLR*, Jun. 2021, doi: 10.48550/arXiv.2010.11929.
- [20] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.