

IMPLEMENTASI DEEP LEARNING MENGGUNAKAN MOBILENETV2 UNTUK KLASIFIKASI JENIS SAMPAH

Didin Setiawan¹, L.Ahmad Syamsul Irfan Akbar², Bulkis Kanata³
^{1,2,3}Teknik Elektro Universitas Matara, Kota Mataram, NTB, Indonesia

ARTICLE INFO

Article history :

Received October 10, 2025
Revised November 28, 2025
Accepted November 29, 2025

Keywords:

Klasifikasi sampah
MobileNetV2
Deep learning
Computer Vision
Aplikasi Android

ABSTRACT

Deep learning-based waste classification is a computer vision solution that can help users identify waste types quickly and efficiently. This study implemented a waste classification application using the MobileNetV2 architecture, where the trained model was integrated directly into an Android application for practical use. This application was designed to recognize three main categories of waste: organic, inorganic, and hazardous waste. Evaluation results showed that the model achieved 96% accuracy in the training stage and 90% in the application testing. In addition, the precision, recall, and F1-score metrics were also consistently high (≥ 0.95 in the model and ≥ 0.90 in the application). The error rate was relatively low, with an average False Positive Rate (FPR) of 1.8% and False Negative Rate (FNR) of 3.7% in the model, and an FPR of 5% and FNR of 10% in the application. These findings prove that the MobileNetV2-based waste classification application is capable of providing reliable performance in supporting waste type identification. With improved dataset quality and model optimization, the application's accuracy has the potential to be further improved, making it ready for use in education, research, and practical implementation in the field

Corresponding Author:

L.Ahmad Syamsul Irfan Akbar, Teknik Elektro Universitas Mataram Affiliation, Kota Mataram, NTB, Indonesia
Email: irfan@unram.ac.id

1. PENDAHULUAN

Masalah sampah di Indonesia merupakan isu lingkungan yang semakin menantang seiring dengan pertumbuhan penduduk dan peningkatan aktivitas manusia. Berdasarkan data Kementerian Lingkungan Hidup dan Kehutanan (KLHK), timbulan sampah nasional pada tahun 2021 mencapai lebih dari 67,8 juta ton, dimana sebagian besar berasal dari sampah rumah tangga[1][4]. Volume ini terus meningkat dengan prediksi bertambahnya konsumsi masyarakat dan urbanisasi. Sampah yang tidak terkelola dengan baik dapat menimbulkan pencemaran lingkungan, risiko kesehatan, dan menambah beban sistem pengelolaan akhir yang ada[3][6]. Sampah secara umum diklasifikasikan menjadi tiga kategori utama yaitu organik, anorganik, dan B3 (Bahan Berbahaya dan Beracun) yang memerlukan penanganan khusus[2][4]. Pemilahan sampah sejak dari sumbernya menjadi hal yang krusial, namun masih minim dilakukan oleh masyarakat[2][7]. Oleh karenanya, pengembangan teknologi klasifikasi sampah otomatis berbasis citra sangat dibutuhkan untuk mempercepat proses pengelolaan dan edukasi masyarakat. Kecerdasan buatan (*Artificial Intelligence*), khususnya teknologi *Computer Vision* dan *Deep Learning*, menawarkan solusi efektif dalam pengenalan dan klasifikasi objek berbasis gambar dengan akurasi tinggi[8]. Salah satu model *deep learning* yang populer adalah *Convolutional Neural Network* (CNN), dengan varian MobileNetV2 yang dirancang untuk efisiensi komputasi dan akurasi tinggi pada perangkat *mobile*[9]. Pendekatan *transfer learning* menggunakan MobileNetV2 memberikan hasil yang menjanjikan dalam klasifikasi gambar, termasuk pengenalan jenis-jenis sampah[9][2]. Penelitian ini bertujuan mengembangkan model klasifikasi sampah otomatis menggunakan MobileNetV2 yang akan dilatih pada dataset citra sampah berbagai kategori. Dengan sistem ini, diharapkan dapat mendukung pengelolaan sampah yang lebih efektif, meningkatkan kesadaran publik, dan membantu pencapaian target pengurangan sampah nasional yang sedang diupayakan pemerintah[3][10][11]

2. METODE

Penelitian ini menggunakan pendekatan eksperimen kuantitatif dengan tujuan mengimplementasikan dan mengevaluasi kinerja model deep learning berbasis arsitektur MobileNetV2 dalam melakukan klasifikasi jenis sampah. Desain penelitian berfokus pada pembangunan sistem klasifikasi berbasis citra dengan tahapan meliputi pengumpulan data, preprocessing, pelatihan model, evaluasi, serta analisis hasil.

2.1. Pengumpulan dan Praproses Data

Dataset penelitian ini terdiri atas 6000 citra jenis sampah (Anorganik, Organik dan B3) yang dikumpulkan dari sumber utama: repositori publik di Kaggle.

Tabel 1 Pembagian rasio Dataset

Jenis Data	Jumlah Data	Persentase
<i>Training</i>	4800	80%
<i>Validation</i>	600	10%
<i>Testing</i>	600	10%
Total	6000	100%

Metode pembagian data yang digunakan adalah *hold out split*, di mana dataset dibagi sejak awal menjadi tiga *subset* independen (80% *training*, 10% *validation*, 10% *test*). Pembagian seperti ini memastikan bahwa data evaluasi (*validation & test*) belum pernah terlihat oleh model selama tahap pelatihan, sehingga memberikan gambaran performa yang lebih realistis.

2.2. Perancangan dan Pelatihan Model

Proses pelatihan dan pengujian model menggunakan arsitektur MobileNet V2 dilakukan dengan memanfaatkan gambar berukuran 160x160x3 piksel. Dataset yang digunakan terdiri dari 4800 data untuk pelatihan, 600 data untuk validasi dan 600 data untuk pengujian. Selama proses pelatihan, arsitektur MobileNet V2 yang digunakan dilengkapi dengan tambahan pemodelan untuk meningkatkan performa model. Beberapa komponen tambahan yang digunakan antara lain Conv2D, Dropout sebesar 0,2 untuk mencegah terjadinya overfitting, Global Average Pooling 2D dan Dense 128 dengan fungsi aktivasi 'softmax' untuk menghasilkan output probabilitas yang lebih akurat. Metode *Early Stopping* diterapkan untuk menghindari terjadinya overfitting, yang menghentikan pelatihan jika tidak ada peningkatan dalam performa model selama beberapa iterasi berturut-turut.

2.3. Evaluasi Model

Model dievaluasi menggunakan data uji yang dipisahkan dari dataset pelatihan, dengan pembagian data menjadi data latih, validasi, dan uji. Kinerja model diukur berdasarkan metrik akurasi, presisi, *recall*, dan F1-*score* untuk memastikan performa klasifikasi yang optimal.


2.4. Perancangan Aplikasi

Perancangan aplikasi klasifikasi sampah berbasis Android dilakukan dengan pendekatan modular agar setiap komponen memiliki fungsi yang jelas dan mudah diintegrasikan. Sistem dirancang terdiri dari tiga lapisan utama, yaitu lapisan antarmuka pengguna (user interface), lapisan pemrosesan data (preprocessing dan inferensi model), serta lapisan keluaran (output hasil klasifikasi)

3. HASIL DAN PEMBAHASAN

3.1. Hasil Implementasi Model

Proses pelatihan dan pengujian model dilakukan pada platform Google *Colaboratory* dengan memanfaatkan arsitektur MobileNet V2. Arsitektur MobileNet V2 dipilih karena kemampuannya dalam menyediakan efisiensi komputasi yang tinggi dan akurasi yang baik, bahkan pada perangkat dengan sumber daya terbatas. Selama pelatihan, model akan dilatih menggunakan dataset pelatihan dan validasi, sedangkan pengujian dilakukan untuk mengevaluasi performa model menggunakan dataset pengujian.

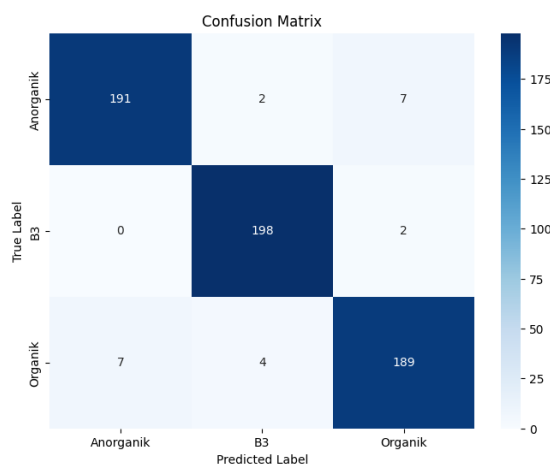


Gambar 1 Training and validation accuracy & loss

Grafik akurasi dan *loss* menunjukkan bahwa selama 70 *epoch*, model berhasil belajar dengan baik. Akurasi pelatihan meningkat mendekati 1 dengan nilai akhir 0.9979, sedangkan akurasi validasi mencapai 0.9700 meskipun mengalami fluktuasi. Kurva biru menggambarkan akurasi pelatihan dan *loss* yang terus membaik, sedangkan kurva oranye untuk validasi menunjukkan hasil yang cukup stabil. *Loss* pelatihan menurun hingga 0.0059, sementara *loss* validasi berada di angka 0.1312. Secara keseluruhan, grafik menunjukkan bahwa model telah mampu mengenali pola dalam data dengan baik dan mencapai performa klasifikasi yang memadai..

3.2. Evaluasi Kinerja Model

Confusion matrix digunakan untuk mengevaluasi performa model dengan menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas pada dataset. Matriks ini memetakan hubungan antara label benar (*actual labels*) dan label prediksi (*predicted labels*) yang dihasilkan oleh model. Setiap elemen dalam confusion matrix mewakili jumlah sampel untuk kombinasi tertentu antara label benar dan prediksi, dengan sumbu horizontal biasanya merepresentasikan prediksi model, dan sumbu vertikal merepresentasikan label sebenarnya. Dengan menggunakan nama kelas dataset pada setiap label, confusion matrix memberikan informasi detail tentang keberhasilan model dalam mengenali pola pada tiap kelas, serta mengidentifikasi kegagalan pada kelas tertentu, seperti jumlah *false positives* (prediksi salah) atau *false negatives* (gagal mendeteksi).



Gambar 2 Confusion matrix

Gambar 2 menunjukkan confusion matrix hasil evaluasi model dalam mengklasifikasikan tiga kelas sampah, yaitu Anorganik, B3, dan Organik. Pada kelas Anorganik, model berhasil mengklasifikasikan sebanyak 191 data dengan benar, namun terdapat 2 data yang salah diklasifikasikan sebagai B3 dan 7 data diklasifikasikan keliru sebagai Organik. Sementara itu, performa model pada kelas B3 menunjukkan hasil yang sangat baik, dengan 198 data berhasil diprediksi dengan benar. Hanya terdapat 2 data yang salah diklasifikasikan sebagai Organik dan tidak ada yang keliru menjadi Anorganik. Untuk kelas Organik, model berhasil mengklasifikasikan 189 data dengan benar, tetapi masih terdapat kesalahan sebanyak 7 data yang diklasifikasikan sebagai Anorganik dan 4 data sebagai B3. Secara umum, hasil dari confusion matrix ini menunjukkan bahwa model memiliki performa klasifikasi yang tinggi dan mampu mengenali ketiga jenis

sampah dengan cukup baik. Jumlah prediksi yang benar pada masing-masing kelas sangat dominan, dan jumlah kesalahan klasifikasi tergolong kecil. Hal ini mengindikasikan bahwa model cukup andal dalam mendeteksi dan membedakan sampah Anorganik, B3, dan Organik, sehingga dapat digunakan sebagai dasar dalam sistem klasifikasi otomatis berbasis *deep learning*. Berdasarkan data confusion matrix yang diperoleh dapat hitung beberapa metrik antara lain:

Akurasi (*Accuracy*)

Akurasi mengukur seberapa sering prediksi model benar secara keseluruhan. Metrik ini memberikan gambaran umum tentang kinerja model.

$$Accuracy = \frac{\text{Jumlah prediksi benar}}{\text{Total seluruh prediksi}} = \frac{191 + 198 + 189}{600} = 0,963$$

Presisi (*Precision*)

Presisi berfokus pada kualitas prediksi positif model. Metrik ini menunjukkan seberapa banyak dari seluruh prediksi positif yang benar-benar positif.

$$Precision_{Anorganik} = \frac{TP}{TP + FP} = \frac{191}{191 + 7} \approx 0,965$$

Recall (*Sensitivitas*)

Recall mengukur sejauh mana model mampu mengidentifikasi semua kasus positif yang sebenarnya. Metrik ini menunjukkan proporsi *true positive* yang berhasil dideteksi dari seluruh *instance positive* yang ada.

$$Recall_{Anorganik} = \frac{TP}{TP + FN} = \frac{191}{191 + 9} = 0,955$$

F1-Score

F1-Score menggabungkan presisi dan *recall* ke dalam satu metrik untuk menyeimbangkan keduanya. Metrik ini memberikan gambaran lebih baik tentang kinerja model, terutama pada dataset yang tidak seimbang.

$$F1 - Score_{Anorganik} = \frac{2 \times Precision \times Recall}{Precision + Recall} = \frac{1,842}{1,920} \approx 0,960$$

Spesifitas (*Specificity*)

Specificity merupakan salah satu metrik evaluasi yang penting dalam sistem klasifikasi, terutama pada kasus klasifikasi biner. Metrik ini digunakan untuk menilai sejauh mana model mampu mengenali dan mengklasifikasikan data negatif dengan benar.

$$Specificity_{Anorganik} = \frac{TN}{TN + FP} = \frac{393}{393 + 7} = 0,983$$

False Positive Rate (FPR)

False Positive Rate (FPR) menunjukkan frekuensi kesalahan model dalam memprediksi data negatif sebagai positif. Dengan kata lain, metrik ini mengukur proporsi data negatif yang keliru diklasifikasikan sebagai positif oleh model.

$$FPR_{Anorganik} = \frac{FP}{FP + TN} = \frac{7}{7 + 393} = 0,017$$

False Negative Rate (FNR)

False Negative Rate (FNR) menggambarkan seberapa sering model tidak berhasil mendeteksi data yang sebenarnya termasuk dalam kategori positif.

$$FNR_{Anorganik} = \frac{FN}{FN + TP} = \frac{9}{9 + 191} = 0,045$$

Setelah dilakukan perhitungan metrik evaluasi secara manual pada kelas Anorganik sebagai contoh, diperoleh hasil bahwa model memiliki tingkat presisi, *recall*, dan F1-score yang tinggi. Perhitungan serupa juga diterapkan pada kelas B3 dan Organik dengan pendekatan yang sama, yaitu dengan menganggap masing-masing kelas sebagai kelas positif secara bergantian, sementara dua kelas lainnya dianggap sebagai kelas negatif. Hasil dari seluruh perhitungan metrik untuk masing-masing kelas, serta nilai rata-rata makro (*macro average*) dan mikro (*micro average*), dirangkum dalam Tabel 2. Tabel ini memberikan gambaran menyeluruh tentang performa model dalam mengenali dan membedakan setiap kelas sampah secara seimbang dan konsisten.

Tabel 2 Hasil Perhitungan Parameter

Metrik	Anorganik	B3	Organik	Macro Avg	Micro Avg
--------	-----------	----	---------	-----------	-----------

<i>Precision</i>	0.965	0.971	0.955	0.964	0.963
<i>Recall</i>	0.955	0.990	0.945	0.963	0.963
<i>F1-Score</i>	0.960	0.980	0.950	0.963	0.963
<i>Specificity</i>	0.983	0.985	0.978	0.982	–
<i>False Positive Rate</i>	0.017	0.015	0.023	0.018	–
<i>False Negative Rate</i>	0.045	0.010	0.055	0.037	–

Berdasarkan hasil evaluasi kinerja model klasifikasi jenis sampah menggunakan arsitektur MobileNetV2, dapat disimpulkan bahwa model menunjukkan performa yang sangat baik dan stabil di seluruh kelas. Akurasi keseluruhan mencapai 96,3%, menunjukkan bahwa sebagian besar sampel berhasil diklasifikasikan dengan benar. Evaluasi per kelas menunjukkan bahwa baik kelas Anorganik, B3, maupun Organik memiliki nilai *precision*, *recall*, dan F1-score yang tinggi, berkisar antara 94% hingga 98%. Nilai *macro average* dan *micro average* yang hampir identik menunjukkan bahwa model mampu menangani distribusi kelas secara seimbang, tanpa terlalu mengandalkan prediksi terhadap kelas mayoritas. Selain itu, nilai *specificity* yang tinggi (rata-rata 98,2%) menunjukkan bahwa model juga efektif dalam mengenali kelas negatif, sehingga mampu menghindari kesalahan prediksi terhadap kelas yang tidak sesuai. Dengan demikian, model yang dibangun memiliki kapabilitas yang baik untuk diterapkan dalam sistem klasifikasi jenis sampah, dan dapat menjadi dasar untuk pengembangan lebih lanjut dalam konteks implementasi nyata, seperti sistem pengelolaan sampah berbasis otomatisasi atau aplikasi edukatif berbasis *mobile*.

3.3. Pengujian Aplikasi

Pengujian dilakukan dengan mengimpor gambar dari galeri menggunakan aplikasi Sipilah. Sebanyak 10 gambar digunakan untuk setiap kelas, yaitu kelas Anorganik, Organik dan B3. Gambar-gambar tersebut kemudian dimasukkan ke dalam aplikasi untuk diidentifikasi.

Tabel 3 Hasil pengujian Model di Aplikasi Android

No	Data Uji	Hasil Prediksi dan Tingkat Probabilitas (%)	Waktu Deteksi (ms)	Hasil
1	Anorganik	Anorganik (99.71)	100	Benar
2	Anorganik	Anorganik (97.96)	107	Benar
3	Anorganik	Anorganik (99.90)	86	Benar
4	Anorganik	Anorganik (96.57)	61	Benar
5	Anorganik	Anorganik (90.81)	79	Benar
6	Anorganik	Anorganik (89.70)	98	Benar
7	Anorganik	B3 (69.21)	85	Salah
8	Anorganik	Anorganik (85.86)	89	Benar
9	Anorganik	Anorganik (87.76)	104	Benar
10	Anorganik	Anorganik (97.69)	105	Benar
11	Organik	Organik (98.51)	137	Benar
12	Organik	Organik (99.94)	88	Benar
13	Organik	Organik (95.29)	95	Benar
14	Organik	Organik (94.30)	95	Benar
15	Organik	Organik (99.69)	105	Benar
16	Organik	Organik (98.94)	97	Benar
17	Organik	Organik (96.74)	93	Benar
18	Organik	Organik (95.78)	106	Benar
19	Organik	Anorganik (67.43)	78	Salah
20	Organik	Organik (99.99)	93	Benar
21	B3	B3 (96.79)	90	Benar
22	B3	B3 (99.97)	96	Benar
23	B3	Objek tidak dikenal (65.60)	68	Salah
24	B3	B3 (98.26)	80	Benar
25	B3	B3 (95.89)	94	Benar
26	B3	B3 (97.67)	87	Benar
27	B3	B3 (99.86)	84	Benar
28	B3	B3 (98.59)	86	Benar
29	B3	B3 (99.98)	84	Benar
30	B3	B3 (98.67)	79	Benar

Aplikasi pada perangkat mobile Android seperti yang ditunjukkan pada gambar 3, memproses gambar dan melakukan prediksi terhadap jenis sampah, apakah termasuk kategori anorganik, organik atau B3. Selain itu, aplikasi juga menampilkan nilai probabilitas, yang menunjukkan persentase keyakinan model terhadap prediksi yang dihasilkan berdasarkan citra gambar yang dimasukkan. Proses ini memungkinkan pengguna untuk mengetahui tingkat keakuratan prediksi berdasarkan data citra yang telah diolah.

Berdasarkan Tabel 3 yang menampilkan hasil pengujian terhadap aplikasi klasifikasi jenis sampah, dilakukan pengujian terhadap 30 data uji yang terbagi merata ke dalam tiga kelas, yaitu “Anorganik”, “Organik”, dan “B3”, masing-masing sebanyak 10 data. Dari hasil pengujian :

- sebanyak 27 data berhasil diklasifikasikan dengan benar, sedangkan 3 data lainnya mengalami kesalahan prediksi. Kesalahan klasifikasi terjadi pada pengujian ke-7, di mana data kelas “Anorganik” salah diprediksi sebagai “B3”; pengujian ke-19, di mana data kelas “Organik” salah diprediksi sebagai “Anorganik”; serta pengujian ke-23, di mana data kelas “B3” tidak dikenali oleh sistem dan dikategorikan sebagai “Objek tidak dikenal”.
- Probabilitas prediksi untuk kelas “Anorganik” berkisar antara 85,86% hingga 99,90%, sementara untuk kelas “Organik” berkisar antara 94,30% hingga 99,99%. Adapun pada kelas “B3”, probabilitas prediksi berkisar antara 95,89% hingga 99,98%. Waktu deteksi sistem pada seluruh pengujian juga relatif cepat, dengan rentang 61 milidetik hingga 137 milidetik per data uji.

Berdasarkan data confusion matrix yang diperoleh dapat hitung beberapa metrik antara lain:



Gambar 3 Aplikasi pada Android

$$\text{Akurasi (Accuracy)} = \frac{\text{Jumlah prediksi benar}}{\text{Total seluruh prediksi}} = \frac{9+9+9}{30} = 0,90$$

$$\text{Presisi (Precision)} : \text{Precision}_{\text{Anorganik}} = \frac{TP}{TP+FP} = \frac{9}{9+1} \approx 0,90$$

$$\text{Recall (Sensitivitas)} : \text{Recall}_{\text{Anorganik}} = \frac{TP}{TP+FN} = \frac{9}{9+1} = 0,90$$

$$\text{F1-Score} : \text{F1-Score}_{\text{Anorganik}} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = \frac{2 \times 0,90 \times 0,90}{0,90 + 0,90} \approx 0,90$$

$$\text{Spesifitas (Specificity)} : \text{Specificity}_{\text{Anorganik}} = \frac{TN}{TN+FP} = \frac{19}{19+1} = 0,95$$

$$\text{False Positive Rate (FPR)} : \text{FPR}_{\text{Anorganik}} = \frac{FP}{FP+TN} = \frac{1}{1+19} = 0,05$$

$$\text{False Negative Rate (FNR)} : \text{FNR}_{\text{Anorganik}} = \frac{FN}{FN+TP} = \frac{1}{1+9} = 0,10$$

Perhitungan serupa juga diterapkan pada kelas B3 dan Organik dengan pendekatan yang sama, yaitu dengan menganggap masing-masing kelas sebagai kelas positif secara bergantian, sementara dua kelas lainnya dianggap sebagai kelas negatif. Hasil dari seluruh perhitungan metrik untuk masing-masing kelas, serta nilai rata-rata makro (*macro average*) dan mikro (*micro average*), dirangkum dalam Tabel 4.7. Tabel ini

memberikan gambaran menyeluruh tentang performa model dalam mengenali dan membedakan setiap kelas sampah secara seimbang dan konsisten

Tabel 4 Hasil Metrik Evaluasi Pengujian Aplikasi

Metrik	Anorganik	Organik	B3	Macro Avg	Micro Avg
<i>Precision</i>	0.90	0.90	0.90	0.90	0.90
<i>Recall</i>	0.90	0.90	0.90	0.90	0.90
<i>F1-Score</i>	0.90	0.90	0.90	0.90	0.90
<i>Specificity</i>	0.95	0.95	0.95	0.95	–
<i>False Positive Rate</i>	0.05	0.05	0.05	0.05	–
<i>False Negative Rate</i>	0.10	0.10	0.10	0.10	–

Berdasarkan hasil pengujian terhadap 30 data uji yang terbagi secara seimbang ke dalam tiga kelas (Anorganik, Organik, dan B3), diperoleh tingkat akurasi model sebesar 90%, yang menunjukkan performa klasifikasi yang sangat baik. Metrik evaluasi lainnya, seperti *precision*, *recall*, dan F1-score untuk setiap kelas juga menunjukkan hasil yang tinggi dan konsisten, dengan nilai rata-rata mendekati 0,90. Hal ini menunjukkan bahwa model cukup seimbang dalam mengenali masing-masing jenis sampah.

4. KESIMPULAN

Berdasarkan hasil evaluasi, model MobileNetV2 menunjukkan kinerja yang sangat baik dengan akurasi 96% pada pelatihan dan performa stabil pada pengujian aplikasi dengan akurasi 90%. Metrik evaluasi menunjukkan nilai *precision*, *recall*, dan F1-score yang konsisten tinggi (≥ 0.95 pada model dan 0.90 pada aplikasi), dengan tingkat kesalahan yang relatif rendah, yaitu *False Positive Rate* (FPR) rata-rata 1,8% dan *False Negative Rate* (FNR) rata-rata 3,7% pada model, serta FPR 5% dan FNR 10% pada pengujian aplikasi. Hasil ini menunjukkan bahwa model mampu mengenali fitur visual dari sampah organik, anorganik, dan B3 dengan baik, sehingga dapat membantu pengguna melakukan pemilahan sampah secara lebih cepat dan efisien. Integrasi ke dalam aplikasi juga memberikan kemudahan penggunaan, menjadikannya sarana edukasi sekaligus alat pendukung pengelolaan sampah berkelanjutan.

DAFTAR PUSTAKA

- [1]Kementerian Lingkungan Hidup dan Kehutanan (KLHK). (2021). Data Timbulan Sampah Nasional. Jakarta: KLHK.
- [2]Yuliasari, R., & Hermana, S. (2020). Perilaku Pemilahan Sampah di Indonesia. *Jurnal Pengelolaan Limbah*, 5(2), 123–130.
- [3]Kementerian Lingkungan Hidup dan Kehutanan (KLHK). (2025). Menteri Lingkungan Hidup: Masalah Sampah Harus Selesai 100% pada 2029. [Online]. Tersedia di: [Kemenlh.go.id](https://kemenlh.go.id) (diakses 2025).
- [4]Ramadhani, F. (2022). Kondisi Lingkungan dan Pengelolaan Sampah di Indonesia. Padang: Universitas Andalas.
- [5]Coaction.id. (2025). Momen Baru untuk Menyongsong Indonesia Bersih Sampah 2025. [Online]. Tersedia di: [Coaction.id](https://coaction.id) (diakses 2025).
- [6]Repository Universitas Muhammadiyah Jakarta (UMJ). (2025). Dampak Pertumbuhan Penduduk Terhadap Produksi Sampah. Jakarta: UMJ.
- [7]Kementerian Lingkungan Hidup dan Kehutanan (KLHK). (2025). HLH 2025: Anak Muda Bicara, Polusi Plastik Harus Segera Berakhir! [Online]. Tersedia di: [KemenLH.go.id](https://kemenlh.go.id) (diakses 2025).
- [8]Indriani, S., Widodo, A., & Priyandoko, R. (2022). Deep Learning dan Computer Vision untuk Pengenalan Objek. *Jurnal Teknologi Informasi*, 10(1), 45–55.
- [9]Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4510–4520.
- [10]Pamungkas, A., & Sudrajat, R. (2022). Implementasi MobileNetV2 untuk Klasifikasi Citra Sampah. *Jurnal Informatika Indonesia*, 11(3), 55–63.
- [11]Kementerian Pendayagunaan Aparatur Negara dan Reformasi Birokrasi (Menpan). (2025). Solusi Sampah Nasional: Teknologi WTE dan RDF Masuk RPJMN 2025–2029. [Online]. Tersedia di: [Menpan.go.id](https://menpan.go.id) (diakses 2025).