

Deteksi Sampah Plastik Berukuran Kecil Menggunakan Arsitektur Faster R-CNN

Imelia Okta Rama Yanti¹, Erwin Dwika Putra^{2*}, Sastya Hendri Wibowo³, Muntahanah⁴

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

imeliaokta235@gmail.com ; erwindwika@gmail.com ; sastyahendriwibowo@gmail.com ; muntahanah@umb.ac.id

Abstrak.

Tujuan : Sampah plastik berukuran kecil, seperti potongan plastik, tutup botol, dan bungkus kemasan, sulit dipilah secara manual karena detailnya terbatas dan sering menyatu dengan latar belakang yang kompleks. Penelitian ini bertujuan menganalisis kinerja arsitektur Faster R-CNN dalam mendeteksi sampah plastik berukuran kecil pada citra digital.

Metode/Design/Pendekatan: Data penelitian berupa 518 citra uji yang berasal dari data primer (60%) dan data sekunder (40%) dengan perbandingan data latih dan data uji sebesar 80:20. Setiap citra dianotasi menggunakan bounding box, kemudian model dilatih menggunakan backbone ResNet-50 FPN dan dievaluasi menggunakan confusion matrix, precision, recall, F1-score, Average Intersection over Union (IoU), dan mean Average Precision (mAP).

Hasil/Temuan: Model mengenali 1.496 dari 1.642 objek ground truth (85,34%) dengan precision 85,34%, recall 91,11%, F1-score 88,13%, rata-rata IoU 88,28%, dan mAP@0.50 sebesar 92,01%. Confidence threshold optimal diperoleh pada 0,85 dengan F1-score 89,44%.

Kebaharuan/Originalitas/Nilai: Penelitian ini secara khusus mengkaji kemampuan Faster R-CNN pada objek sampah plastik berukuran sangat kecil dan tipis pada berbagai kondisi pencahayaan dan latar belakang, sebuah aspek yang masih terbatas dikaji pada penelitian deteksi sampah plastik sebelumnya, sekaligus menunjukkan bahwa keterbatasan utama model terletak pada kemampuan menemukan objek dan bukan pada ketepatan lokalisasi bounding box.

Keywords: Faster R-CNN, deteksi objek, sampah plastik, deep learning, citra digital

Abstract.

Purpose: Small-sized plastic waste, such as plastic fragments, bottle caps, and packaging wrappers, is difficult to sort manually because of its limited visual detail and frequent blending with complex backgrounds. This study aims to analyze the performance of the Faster R-CNN architecture in detecting small plastic waste in digital images.

Methods/Study design/approach: The research data consisted of 518 test images obtained from primary (60%) and secondary (40%) sources, with an 80:20 training-to-testing split. Each image was annotated with bounding boxes, and the model was trained using a ResNet-50 FPN backbone, then evaluated using a confusion matrix, precision, recall, F1-score, Average Intersection over Union (IoU), and mean Average Precision (mAP).

Result/Findings: The model correctly identified 1,496 of 1,642 ground-truth objects (85.34%), achieving 85.34% precision, 91.11% recall, an 88.13% F1-score, an 88.28% average IoU, and a 92.01% mAP@0.50. The optimal confidence threshold was found at 0.85, yielding an F1-score of 89.44%.

Novelty/Originality/Value: This study specifically examines the capability of Faster R-CNN in detecting very small and thin plastic waste objects under varied lighting and background conditions, an aspect still limited in prior plastic-waste detection research, while showing that the model's main limitation lies in object discovery rather than bounding-box localization accuracy.

Keywords: Faster R-CNN, object detection, plastic waste, deep learning, digital image

Article history:

Received, 2026-08-23

Revised, 2026-08-24

Accepted, 2026-10-08

*Corresponding author.

Name author.

Email addresses: mail@gmail.com

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



PENDAHULUAN

Permasalahan sampah merupakan salah satu isu lingkungan yang terus meningkat di berbagai negara, termasuk Indonesia, seiring dengan pertumbuhan penduduk dan tingginya aktivitas konsumsi masyarakat. Salah satu jenis sampah yang paling dominan dan menjadi perhatian utama adalah sampah plastik, karena sifatnya yang sulit terurai secara alami sehingga dapat bertahan di lingkungan dalam jangka waktu yang sangat lama dan mencemari ekosistem darat maupun perairan [1], [2].

Plastik banyak digunakan dalam kehidupan sehari-hari karena memiliki berbagai keunggulan, seperti ringan, kuat, tahan terhadap air, serta mudah dibentuk menjadi berbagai produk [3], [4]. Namun, plastik memiliki sifat yang sulit terurai secara alami sehingga dapat bertahan di lingkungan dalam jangka waktu yang sangat lama. Kondisi ini menyebabkan pencemaran lingkungan yang berdampak pada ekosistem darat maupun perairan [5], [6], [7].

Salah satu kendala utama dalam pengelolaan sampah plastik adalah proses pemilahan yang masih dilakukan secara manual, sehingga membutuhkan waktu relatif lama dan memiliki tingkat kesalahan yang cukup tinggi [8], [9]. Permasalahan tersebut menjadi lebih kompleks ketika objek yang harus dipilah berukuran kecil, seperti potongan plastik, tutup botol, dan bungkus kemasan, karena objek tersebut memiliki resolusi visual rendah, detail fitur yang terbatas, dan rentan menyatu dengan latar belakang yang kompleks [2], [4].

Dalam konteks pengolahan citra digital, objek berukuran kecil memiliki karakteristik yang menantang, seperti resolusi rendah, detail fitur yang terbatas, serta rentan terhadap gangguan latar belakang [2], [10]. Hal ini menyebabkan proses deteksi objek kecil menjadi lebih sulit dibandingkan dengan objek berukuran besar, sehingga diperlukan pendekatan yang mampu menangani kompleksitas tersebut secara efektif [11], [12].


Perkembangan teknologi deep learning membuka peluang besar dalam mengatasi permasalahan deteksi objek secara otomatis. Berbagai pendekatan telah dikembangkan pada bidang computer vision, mulai dari *Convolutional Neural Network (CNN)* untuk klasifikasi citra [3], [13], *You Only Look Once (YOLO)* untuk deteksi satu tahap yang cepat [1], hingga *Faster R-CNN* sebagai detektor dua tahap yang dikenal unggul dalam akurasi lokalisasi objek [2], [4].

Penelitian menggunakan CNN, mampu memperoleh akurasi klasifikasi di atas 90%, namun keduanya hanya berfokus pada klasifikasi jenis sampah tanpa mampu menentukan lokasi objek pada citra [5], [6]. Pendekatan YOLO menunjukkan kecepatan proses yang baik, tetapi performanya cenderung menurun ketika mendeteksi objek berukuran kecil pada kondisi citra yang kompleks [1], [14]. Di sisi lain, penelitian dengan *Faster R-CNN* pada menghasilkan nilai mAP@0.50 sebesar 82,64% dalam mendeteksi sampah plastik di lingkungan perairan, namun kajian yang secara khusus membahas kemampuan *Faster R-CNN* pada objek sampah plastik berukuran sangat kecil dengan berbagai kondisi pencahayaan dan latar belakang masih terbatas [2].

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan untuk menganalisis kinerja metode *Faster R-CNN* dalam mendeteksi sampah plastik berukuran kecil pada citra digital, mengetahui performa model berdasarkan parameter precision, recall, dan F1-score, serta menganalisis kemampuan model pada berbagai kondisi citra, termasuk variasi pencahayaan, latar belakang, dan bentuk objek.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental dengan menerapkan arsitektur *Faster R-CNN* untuk mendeteksi sampah plastik berukuran kecil pada citra digital. Tahapan penelitian meliputi pengumpulan dataset, anotasi bounding box, preprocessing, pembagian dataset, training model, testing, hingga evaluasi kinerja model. Alur penelitian secara lengkap ditampilkan pada Gambar 1.



Gambar 1. Framework penelitian deteksi sampah plastik menggunakan Faster R-CNN

Faster R-CNN merupakan metode deteksi objek dua tahap (two-stage detector) yang mengintegrasikan proses pembangkitan region proposal ke dalam jaringan saraf melalui Region Proposal Network (RPN), sehingga proses pencarian wilayah yang berpotensi mengandung objek dapat dilakukan lebih efisien dibandingkan metode R-CNN maupun Fast R-CNN sebelumnya [6]. Tahap pertama menghasilkan kandidat wilayah objek (region proposal) menggunakan RPN, sedangkan tahap kedua melakukan klasifikasi objek dan regresi bounding box terhadap kandidat wilayah tersebut. Pada penelitian ini, backbone yang digunakan adalah ResNet-50 Feature Pyramid Network (FPN), yang bertugas mengekstraksi fitur citra berupa tepi, tekstur, bentuk, dan pola objek.

Kesesuaian antara bounding box hasil prediksi dan ground truth diukur menggunakan Intersection over Union (IoU), yang dirumuskan sebagai:

$$IoU = \text{Area}(Bp \cap Bgt) / \text{Area}(Bp \cup Bgt) \quad (1)$$

dengan Bp adalah bounding box hasil prediksi dan Bgt adalah bounding box ground truth. Kandidat wilayah objek yang saling tumpang tindih secara berlebihan disaring menggunakan Non-Maximum Suppression (NMS) agar hanya kotak dengan skor keyakinan tertinggi yang dipertahankan.

Pengumpulan Data dan Dataset

Data penelitian dikumpulkan dari data primer sebesar 60%, yaitu citra yang diambil secara langsung menggunakan kamera smartphone pada berbagai kondisi lingkungan, dan data sekunder sebesar 40% yang diperoleh dari dataset publik. Objek yang menjadi fokus penelitian meliputi tiga kategori sampah plastik berukuran kecil yang umum ditemukan di lingkungan, sebagaimana disajikan pada Tabel 1.

Tabel 1. Kategori dataset sampah plastik berukuran kecil

No	Kategori	Label	Deskripsi	Contoh Objek
1	Sedotan Plastik	Plastic straw	Limbah plastik berbentuk sedotan	Sedotan minuman
2	Tutup Botol Plastik	Plastic cup	Bagian penutup botol plastik	Tutup botol air mineral, minuman soda
3	Bungkus Plastik	Plastic wrapper	Sampah plastik berbentuk kemasan makanan/minuman ringan	Bungkus snack, permen, mi instan

Setiap citra dianotasi menggunakan bounding box dengan bantuan perangkat LabelImg dan Roboflow untuk menandai posisi serta label objek. Variasi data dijaga melalui perbedaan pencahayaan (terang dan redup), sudut pengambilan gambar, serta latar belakang seperti tanah, aspal, rumput, dan pasir, agar model mampu mengenali objek pada kondisi yang mendekati kondisi nyata di lapangan. Setelah melalui tahap pemeriksaan kualitas, resize,

dan augmentasi, dataset dibagi menjadi data latih sebesar 80% dan data uji sebesar 20%, sehingga diperoleh 518 citra uji dengan total 1.642 objek sampah plastik pada ground truth.

Evaluasi Kinerja Model

Kinerja model dievaluasi dengan membandingkan hasil prediksi terhadap label ground truth untuk memperoleh nilai True Positive (TP), False Positive (FP), dan False Negative (FN), yang selanjutnya digunakan untuk menghitung precision, recall, dan F1-score sebagai berikut:

$$Precision = TP / (TP + FP) \quad (2)$$

$$Recall = TP / (TP + FN) \quad (3)$$

$$F1-score = 2 \times (Precision \times Recall) / (Precision + Recall) \quad (4)$$

Selain ketiga metrik tersebut, kinerja model juga dievaluasi menggunakan rata-rata IoU untuk mengukur ketepatan lokalisasi *bounding box*, *mean Average Precision* (mAP@0.50) untuk mengukur kemampuan deteksi secara menyeluruh, serta pengujian variasi confidence threshold untuk menentukan titik keseimbangan terbaik antara precision dan recall.

HASIL DAN PEMBAHASAN

Hasil Pengujian Model

Pengujian dilakukan dengan memasukkan 518 citra uji ke dalam model Faster R-CNN yang telah dilatih. Model menghasilkan bounding box beserta confidence score pada setiap objek sampah plastik yang berhasil dikenali. Gambar 2 memperlihatkan hasil deteksi pada citra dengan pencahayaan malam hari yang minim, di mana model berhasil mendeteksi seluruh 10 objek sampah plastik yang terdapat pada citra dengan nilai keyakinan antara 0,63 hingga 1,00.




Gambar 2. Hasil deteksi model Faster R-CNN pada kondisi pencahayaan minim

Kemampuan model juga diuji pada citra dengan latar belakang kompleks berupa permukaan aspal yang bercampur dengan sampah lain, seperti puntung rokok dan bungkus makanan (Gambar 3). Meskipun objek target berwarna bening dengan kontras rendah terhadap latar belakang, model tetap berhasil mendeteksi objek tersebut dengan confidence sebesar 1,00, yang menunjukkan kemampuan model dalam membedakan objek target dari background clutter di sekitarnya.




Gambar 3. Hasil deteksi model pada latar belakang kompleks

Sebaliknya, Gambar 4 menunjukkan salah satu kondisi kelemahan model. Objek sampah plastik berwarna kuning yang berukuran sangat kecil dan tipis di tengah permukaan jalan tidak berhasil dideteksi karena bentuknya menyerupai goresan atau retakan pada aspal serta kontras warnanya yang rendah terhadap latar belakang. Berdasarkan keseluruhan 518 citra uji, terdapat 27 citra (5,21%) yang tidak menghasilkan satu pun deteksi meskipun objek sampah plastik ada pada citra tersebut.



Gambar 4. Contoh kegagalan deteksi pada objek berukuran sangat kecil dan tipis



Gambar 5. Confusion matrix hasil pengujian model


Berdasarkan confusion matrix pada Gambar 5, diperoleh $TP = 1.496$, $FP = 257$, dan $FN = 146$. Nilai tersebut digunakan untuk menghitung precision, recall, F1-score, rata-rata IoU, dan $mAP@0.50$ sebagaimana dirangkum pada Tabel 2.

Tabel 2. Ringkasan hasil evaluasi kinerja model Faster R-CNN

Parameter Evaluasi	Nilai	Keterangan
True Positive (TP)	1.496	Objek plastik terdeteksi benar
False Positive (FP)	257	Prediksi plastik yang keliru
False Negative (FN)	146	Objek plastik tidak terdeteksi
Precision	85,34%	Ketepatan prediksi model
Recall	91,11%	Kemampuan menemukan objek
F1-score	88,13%	Keseimbangan precision & recall
Rata-rata IoU	88,28%	Ketepatan lokalisasi bounding box
mAP@0.50	92,01%	Rata-rata precision pada IoU 0,50
F1-score terbaik	89,44% (threshold 0,85)	Titik keseimbangan optimal


Nilai precision sebesar 85,34% menunjukkan bahwa sebagian besar prediksi model merupakan objek yang sesuai dengan kelas target, sedangkan recall sebesar 91,11% menunjukkan kemampuan model dalam menemukan objek yang sebenarnya ada pada citra. Nilai recall yang lebih tinggi dibandingkan precision pada perhitungan awal, namun performa keseluruhan tetap menunjukkan bahwa tantangan utama model terletak pada kemampuan menemukan seluruh objek kecil, bukan pada ketepatan prediksi yang telah dihasilkan.

Pengujian pada berbagai nilai confidence threshold menunjukkan bahwa F1-score terbaik diperoleh pada threshold 0,85 dengan nilai 89,44%, sebagaimana ditampilkan pada Gambar 6. Pada threshold yang rendah, model menerima lebih banyak prediksi sehingga recall meningkat namun precision menurun akibat bertambahnya false positive. Sebaliknya, threshold yang tinggi membuat model lebih selektif sehingga precision meningkat, tetapi berisiko menghilangkan objek kecil dengan confidence rendah.




Gambar 6. F1-score terhadap variasi confidence threshold

Distribusi nilai IoU pada Gambar 7 menunjukkan bahwa sebagian besar prediksi memiliki IoU pada rentang 0,80 hingga 1,00, dengan konsentrasi terbesar di sekitar 0,90–0,95. Nilai rata-rata IoU sebesar 88,28% menunjukkan bahwa ketika objek berhasil dideteksi, posisi *bounding box* yang dihasilkan model cenderung dekat dengan ground truth, sehingga keterbatasan utama model bukan pada ketepatan lokasi, melainkan pada kemampuan menemukan objek yang sulit terlihat.



Gambar 7. Distribusi nilai IoU pada objek yang berhasil terdeteksi

Kurva precision-recall pada Gambar 8 memperlihatkan nilai precision yang tetap mendekati 1,00 pada tingkat recall rendah hingga menengah, kemudian menurun perlahan seiring bertambahnya recall, terutama ketika mendekati recall 0,90. Kondisi ini menghasilkan nilai $mAP@0.50$ sebesar 92,01%, yang menunjukkan bahwa model mampu mempertahankan precision yang tinggi pada berbagai tingkat recall meskipun terdapat trade-off di antara keduanya.



Gambar 8. Kurva precision-recall model Faster R-CNN

Hasil penelitian menunjukkan bahwa Faster R-CNN mampu mendeteksi sampah plastik berukuran kecil dengan performa yang baik, ditopang oleh mekanisme Region Proposal Network (RPN) yang memusatkan proses klasifikasi hanya pada wilayah yang diperkirakan mengandung objek, sehingga lebih efisien dibandingkan pendekatan klasifikasi citra konvensional yang tidak mampu menentukan lokasi objek [7], [8]. Dibandingkan dengan penelitian [11] yang memperoleh $mAP@0.50$ sebesar 82,64% pada deteksi sampah plastik di lingkungan perairan, penelitian ini menghasilkan $mAP@0.50$ yang lebih tinggi yaitu 92,01%, meskipun objek yang dideteksi berukuran lebih kecil dan lebih beragam kondisi latar belakangnya.

Namun demikian, hasil recall sebesar 91,11% dan tingkat kegagalan deteksi sebesar 5,21% pada citra uji menunjukkan bahwa objek yang berukuran sangat kecil, tipis, dan memiliki kontras rendah terhadap latar belakang tetap menjadi tantangan utama, karena informasi fitur yang dapat diekstraksi oleh backbone CNN menjadi terbatas ketika area objek terlalu kecil dibandingkan keseluruhan citra. Sebaliknya, variasi pencahayaan dan kompleksitas latar belakang terbukti masih dapat ditangani dengan baik oleh model selama karakteristik visual objek masih cukup jelas untuk dibedakan.

Berdasarkan rumusan masalah penelitian, dapat disimpulkan bahwa metode Faster R-CNN mampu mendeteksi sampah plastik berukuran kecil dengan performa yang cukup baik (precision 85,34%, recall 91,11%, F1-score 88,13%), memiliki kemampuan lokalisasi bounding box yang baik (rata-rata IoU 88,28%; $mAP@0.50$ 92,01%),

dan mampu bekerja pada berbagai kondisi citra meskipun kesulitan tetap muncul pada objek yang sangat kecil, tipis, dan berkontras rendah terhadap latar belakang.

KESIMPULAN

Berdasarkan hasil penelitian, pengujian, dan pembahasan mengenai penerapan metode *Faster R-CNN* untuk mendeteksi sampah plastik berukuran kecil pada citra digital, dapat disimpulkan bahwa model mampu mengenali 1.496 dari 1.642 objek *ground truth* (85,34%) dengan *precision* 85,34%, *recall* 91,11%, F1-score 88,13%, rata-rata IoU 88,28%, dan mAP@0.50 sebesar 92,01%. *Confidence threshold* optimal diperoleh pada 0,85 dengan F1-score tertinggi sebesar 89,44%. Model menunjukkan kemampuan lokalisasi bounding box yang baik ketika objek berhasil dideteksi, sehingga keterbatasan utama model lebih berkaitan dengan kemampuan menemukan objek yang berukuran sangat kecil, tipis, dan berkontras rendah terhadap latar belakang, dibandingkan dengan ketepatan penentuan lokasi objek. Penelitian selanjutnya disarankan untuk menambah variasi data latih pada objek berukuran sangat kecil, menerapkan teknik data augmentation tambahan yang berfokus pada perbesaran area kecil, melakukan eksperimen lanjutan terhadap ukuran *anchor box*, serta membandingkan performa *Faster R-CNN* dengan arsitektur deteksi objek lain seperti YOLO atau RetinaNet untuk memperoleh gambaran perbandingan yang lebih menyeluruh dalam mendeteksi sampah plastik berukuran kecil

REFERENSI

- [1] Visen and N. Charibaldi, "Penerapan Object Detection Menggunakan Deep Learning Yolov8 Untuk Mengidentifikasi Sampah Anorganik (Maksimal Sepuluh Objek) Dalam Satu Citra," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 1, pp. 195–202, Feb. 2025, doi: 10.25126/jtiik.2025129012.
- [2] N. F. Fahmitra, F. P. Albana, and M. R. Rathomi, "Klasifikasi Sampah Plastik di Laut Menggunakan Algoritma *Faster R-CNN* (Studi Kasus Tanjungpinang)," *J. Sains dan Inform.*, vol. 12, no. 1, pp. 1–10, Jun. 2026, doi: 10.34128/jsi.v12i1.1606.
- [3] L. Faizal, Y. Yuyun, and H. Hazriani, "Identifikasi Sampah Plastik Menggunakan Algoritma Deep Learning," *J. Ilm. Sist. Inf. dan Tek. Inform.*, vol. 6, no. 2, pp. 162–171, Oct. 2023, doi: 10.57093/jisti.v6i2.176.
- [4] M. Resa Arif Yudianto, P. Sukmasetya, R. Abul Hasani, and D. Sasongko, "Pengaruh Data Preprocessing terhadap Imbalanced Dataset pada Klasifikasi Citra Sampah menggunakan Algoritma Convolutional Neural Network," *Build. Informatics, Technol. Sci.*, vol. 4, no. 3, Dec. 2022, doi: 10.47065/bits.v4i3.2575.
- [5] F. Rifaldy, M. I. Prayoga, and L. S. Harahap, "Pengembangan Sistem Klasifikasi Sampah Untuk Daur Ulang Otomatis Berbasis Citra Menggunakan Model Cnn," *Melek IT Inf. Technol. J.*, vol. 11, no. 1, pp. 11–20, Jun. 2025, doi: 10.30742/melekitjournal.v11i1.397.
- [6] 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.
- [7] M. Fadli Setiawan, "IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) PADA KLASIFIKASI GRADE JENIS SAMPAH PLASTIK DAN KALENG," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 3S1, Oct. 2025, doi: 10.23960/jitet.v13i3S1.7805.
- [8] H. Prayuda, M. R. Rathomi, and N. F. Fahmitra, "Klasifikasi Sampah Laut Jenis Limbah Plastik Menggunakan Metode Convolutional Neural Network Backpropagation (Perairan Kota Tanjungpinang)," *J. Sains dan Inform.*, vol. 11, no. 2, pp. 130–139, Nov. 2025, doi: 10.34128/jsi.v11i2.1644.
- [9] V. R. Ho, S. Devella, and D. Alamsyah, "Klasifikasi Media Pembuangan Sampah Menggunakan Metode Resnet101-V2," *MDP Student Conf.*, vol. 2, no. 1, pp. 151–157, Apr. 2023, doi: 10.35957/mdp-sc.v2i1.4338.
- [10] Muhamad Auliya and Zaehol Fatah, "Pemanfaatan Google Teachable Machine Untuk Klasifikasi Sampah Daur Ulang," *J. Mhs. Tek. Inform.*, vol. 4, no. 1, pp. 112–117, Apr. 2025, doi: 10.35473/jamastika.v4i1.3641.
- [11] D. Y. Prakosa, Reno Oktavian, and Agio Prima Kardana, "Klasifikasi Citra Sampah Daur Ulang Menggunakan Arsitektur MobileNetV2 dengan Strategi Fine-Tuning," *J. Inf. Syst. Appl. Dev.*, vol. 4, no. 1, pp. 169–174, Mar. 2026, doi: 10.26905/jisad.v4i1.16740.
- [12] Kartiko, A. Prima Yudha, N. Dimas Aryanto, and M. Arya Farabi, "Klasifikasi Sampah di Saluran Air Menggunakan Algoritma CNN," *Indones. J. Data Sci.*, vol. 3, no. 2, pp. 72–81, Jul. 2022, doi: 10.56705/ijodas.v3i2.33.
- [13] R. Bijak, N. Kholis, and F. Utaminingrum, "Rancang Bangun Sistem Klasifikasi Sampah Anorganik Kantor menggunakan Deep Learning Arsitektur Xception berbasis NVIDIA Jetson Nano," *J. Pengemb.*

Teknol. Inf. dan Ilmu Komput., vol. 6, no. 6, pp. 2681–2686, 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>

- [14] W. Hutamaputra, R. Y. Krisnabayu, M. Mawarni, N. Yudistira, and F. A. Bachtiar, “Perbandingan Convolutional Neural Network VGG16 dan ResNet34 pada Sistem Klasifikasi Sampah Botol,” *J. Teknol. dan Sist. Komput.*, vol. 10, no. 2, 2022, doi: 10.14710/jtsiskom.2021.14045.