

Deteksi Sampah Organik dan Anorganik Menggunakan Model YOLO Berbasis Dataset Roboflow

Miftahuddin Fahmi, Faisal Reza Pradhana, Muhammad Daffa Nurahman

Program Studi Teknik Informatika Fakultas Sains dan Teknologi

Universitas Darussalam Gontor

Ponorogo, Indonesia

miftahuddinmahmi@unida.gontor.ac.id, faisalrezapradhana@unida.gontor.ac.id,

muhammaddaffanurahman44@student.cs.unida.gontor.ac.id

Abstract- Waste separation practices in Indonesia remain far from optimal due to limited supporting infrastructure and low public participation, indicating the need for more automated approaches that reduce reliance on manual sorting. This study investigates the capability of the YOLOv8 object detection algorithm to classify organic and inorganic waste from images. A dataset of 3,169 annotated images sourced from the Roboflow platform was used, and the model was trained through a transfer learning scheme using the YOLOv8n pretrained weights at a resolution of 640×640 pixels for 100 epochs. Model performance was evaluated using Precision, Recall, and mean Average Precision (mAP). The resulting scores—0.968 for precision, 0.970 for recall, 0.986 for $mAP@0.5$, and 0.922 for $mAP@0.5:0.95$ —demonstrate that YOLOv8 can reliably distinguish waste categories with high accuracy. These findings highlight the potential of YOLOv8-based object detection as a foundational component in future computer vision-driven waste management systems.

Keywords: YOLOv8, Object Detection, Organic Waste, Inorganic Waste, Smart Waste Management

Abstrak- Upaya memilah sampah organik dan anorganik di Indonesia masih jauh dari ideal, terutama karena keterbatasan sarana pendukung dan rendahnya partisipasi masyarakat. Kondisi ini menunjukkan perlunya pendekatan yang lebih otomatis agar proses identifikasi jenis sampah tidak sepenuhnya bergantung pada interaksi manusia. Penelitian ini mengeksplorasi kemampuan algoritma deteksi objek YOLOv8 dalam membedakan dua kategori sampah melalui citra. Sebanyak 3.169 gambar dari platform Roboflow digunakan sebagai dataset, kemudian model dilatih menggunakan skema transfer learning dengan bobot awal YOLOv8n pada resolusi 640×640 piksel selama 100 *epoch*. Kinerja model dinilai menggunakan metrik Precision, Recall, serta mean Average Precision (mAP). Model menghasilkan *Precision* 0,968, *Recall* 0,970, *mAP@0,5* sebesar 0,986, dan *mAP@0,5:0,95* mencapai 0,922. Hasil tersebut mengindikasikan bahwa YOLOv8 mampu melakukan identifikasi objek sampah secara akurat dan stabil, sehingga berpotensi menjadi komponen inti dalam pengembangan sistem pengelolaan sampah berbasis visi komputer di masa depan.

Kata Kunci: YOLOv8, Deteksi Objek, Sampah Organik, Sampah Anorganik, Smart Waste Management

1. Pendahuluan

Masalah pengelolaan limbah di Indonesia masih menjadi tantangan besar yang membutuhkan solusi yang terus berkelanjutan. Berdasarkan informasi dari Kementerian Lingkungan Hidup dan Kehutanan (KLHK) mengindikasikan bahwa jumlah sampah yang dihasilkan secara nasional terus berfluktuasi dari 67,8 juta ton pada 2020 menjadi 33,8 juta ton pada 2024 [1]. Fluktuasi ini memperlihatkan belum optimalnya sistem pengelolaan dan pemilahan sampah di tingkat masyarakat maupun fasilitas pengolahan. Di sisi lain, efektivitas

pemilahan sampah organik dan anorganik (langkah awal yang krusial dalam rantai pengelolaan sampah) belum optimal karena rendahnya kesadaran dan pengetahuan masyarakat. Survei Lembaga Jakpat mengungkapkan bahwa lebih dari 61,6% masyarakat ingin memilah sampah namun terhambat oleh keterbatasan sarana yang sesuai [2]. Data dari GoodStats memperlihatkan bahwa kebiasaan pemilahan sampah belum mengakar kuat: hanya 31,4% responden yang melakukannya secara rutin, sementara 48,1% melakukannya sporadis dan 20,5%

Vol.16 no.2 | Desember 2025

EXPLORE : ISSN: 2087-2062, Online ISSN: 2686-181X / DOI: <http://dx.doi.org/10.36448/jsit.v16i2.4600>



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/)

sama sekali tidak memilah. Pola ini mengindikasikan adanya hambatan perilaku dan rendahnya urgensi pemilahan pada tingkat rumah tangga [3]. Selain itu, kebiasaan buang sampah sembarangan masih sering ditemui, karena banyak individu yang merasa urusan sampah “bukan tanggung jawabnya” [4]. Keadaan ini menggambarkan bahwa walaupun pemahaman tentang membuang sampah di Lokasi yang tepat cukup baik, pemahaman dan kebiasaan memilah sampah-sampah tersebut belum terpadu dengan baik dalam kehidupan sehari-hari.

Teknologi computer vision menawarkan solusi inovatif untuk membantu proses pemilahan sampah secara otomatis dan efisien. Dalam berbagai implementasi visi komputer yang menuntut respons cepat, YOLO (You Only Look Once) menjadi pendekatan yang banyak digunakan karena melakukan proses deteksi dalam satu kali inferensi. Arsitektur ini memungkinkan model mengekstraksi fitur dan memprediksi lokasi objek secara bersamaan, sehingga menghasilkan deteksi yang cepat sekaligus tetap mempertahankan ketelitian identifikasinya. Penelitian Pratiwi (2025) menunjukkan bahwa penerapan YOLOv8 mampu mencapai precision hingga 98% dalam mendeteksi sampah pada berbagai kondisi pencahayaan[5], sedangkan Yozika Arvio dkk. (2023) mengimplementasikan YOLOv8 untuk klasifikasi sampah organik dan anorganik dengan hasil yang menjanjikan [6].


Penelitian ini berfokus pada penerapan YOLOv8 untuk mendeteksi dua jenis sampah—organik dan

anorganik—menggunakan dataset beranotasi format COCO berjumlah 3.169 citra. Tujuannya adalah untuk mengukur kinerja model dalam hal *Precision*, *Recall*, dan mean Average Precision (*mAP*), sehingga dapat memberikan kontribusi pada pengembangan sistem deteksi otomatis yang mendukung pengelolaan sampah cerdas (smart waste management) di Indonesia.

2. Metodologi

A. Desain Penelitian

Kerangka *CRISP-DM* (Cross-Industry Standard Process for Data Mining) diadopsi dalam penelitian ini untuk mengatur tahapan pengembangan sistem deteksi sampah secara sistematis. Model proses ini memberikan struktur yang jelas dari identifikasi kebutuhan hingga penilaian performa model. Model proses ini dipilih karena memberikan alur kerja yang terstruktur untuk proyek berbasis data, mulai dari memahami permasalahan sampai mengevaluasi hasil model. Secara umum, *CRISP-DM* terdiri dari enam tahapan, yaitu Business Understanding, Data Understanding, Data Preparation, Modelling, Evaluation, dan Deployment [7]. Namun, dalam penelitian ini, proses hanya dilakukan hingga tahap Evaluation, karena fokus utama penelitian ini adalah mengenai penerapan serta pengujian kinerja *model You Only Look Once* (YOLO) dalam mendeteksi objek sampah organik dan anorganik. Alur lengkap tahapan penelitian sesuai dengan metode *CRISP-DM* terlihat pada Gambar 1.



Gambar 1. Metode CRISP-DM [7]

B. Dataset dan Pengolahan Data

Dataset dari Roboflow berisi 3.169 citra sampah yang terbagi ke dalam dua kelas, yaitu Organik dan Anorganik, dengan 2.018 citra memiliki anotasi objek dalam format YOLO. Selain informasi *bounding box*, dataset ini juga mencakup beragam kondisi pengambilan gambar. Citra tidak diperoleh dari lingkungan terkontrol, melainkan dari situasi nyata dengan variasi pencahayaan, latar belakang

yang kompleks, objek yang bertumpuk (*occlusion*), serta beberapa sampel yang buram atau memiliki noise visual. Karakteristik ini menjadikan dataset lebih representatif untuk skenario deteksi dunia nyata.

Sebelum digunakan, data melalui beberapa tahap pengolahan, meliputi :

1. *Resizing* citra menjadi 640 x 640 piksel agar sesuai dengan ukuran input model YOLO

2. Normalisasi dan Augmentasi, seperti *flip horizontal*, rotasi, dan penyesuaian kecerahan, untuk meningkatkan variasi data dan mengurangi resiko *overfitting*.
3. Pembagian Dataset menjadi *training* (60%), *validation* (20%), dan *testing* (20%) secara acak agar distribusi kelas tetap seimbang

Seluruh proses dilakukan melalui *Roboflow* dan disimpan dalam format yang kompatibel dengan model YOLOv8. Tahapan ini memastikan data siap digunakan untuk pelatihan model dengan kualitas dan konsistensi yang optimal.

C. Arsitektur Model YOLO

Model YOLOv8 merupakan generasi terbaru dari keluarga YOLO yang dikembangkan oleh *Ultralytics* dengan tujuan meningkatkan efisiensi deteksi dan akurasi dalam waktu inferensi yang singkat [8]. YOLOv8 mengadopsi pendekatan *anchor-free detection*, yang dimana proses *bounding box* tidak lagi bergantung pada anchor box seperti pada YOLOv5. Pendekatan ini menyederhanakan proses pelatihan dan memperbaiki kemampuan generalisasi model [9].

Struktur utama YOLOv8 dibangun melalui pemisahan modul pemrosesan fitur ke dalam tiga komponen inti, yaitu : *Backbone*, *Neck*, *Head*. Bagian *Backbone* menggunakan desain *CSPDarknet* yang sudah dimodifikasi dengan blok *C2f* (Coarse-to-Fine) untuk mengekstraksi fitur penting dari citra tanpa meningkatkan kompleksitas model secara signifikan [8]. Bagian *Neck* mengimplementasikan *Path Aggregation Network* (PANet) untuk menggabungkan fitur dari berbagai level, sehingga model mampu mendeteksi objek dengan ukuran yang beragam secara lebih stabil. Sementara itu, *Head* pada YOLOv8 menggunakan

struktur *decoupled head* untuk memisahkan jalur prediksi klasifikasi dan regresi bounding box. Pendekatan ini meningkatkan stabilitas pelatihan dan akurasi deteksi [10].

Dengan kombinasi *C2f-backbone*, *PANet-neck*, dan *anchor-free decoupled head*, YOLOv8 memberikan peningkatan signifikan pada efisiensi serta kinerja deteksi real-time. Oleh karena itu, dalam penelitian ini YOLOv8 digunakan untuk mendeteksi dan mengklasifikasikan objek sampah organik dan anorganik dari citra yang telah dianotasi.

D. Pelatihan Model

Pelatihan model dilakukan menggunakan pendekatan supervised learning dengan arsitektur YOLOv8, yang menggabungkan proses klasifikasi dan lokalisasi objek dalam satu tahap inferensi [11]. Model dilatih menggunakan pre-trained weights *yolov8n.pt* dari dataset COCO melalui metode transfer learning, untuk mempercepat konvergensi serta meningkatkan performa pada dataset deteksi sampah [12].

Dataset terdiri atas dua kelas, yaitu Sampah Organik dan Sampah Anorganik, dengan format anotasi COCO. Proses pelatihan dijalankan selama 100 epoch dengan

resolusi gambar 640×640 piksel, batch size 32, dan penerapan early stopping dengan nilai patience sebesar 15 untuk mencegah *overfitting*. Pelatihan dilakukan menggunakan pustaka Ultralytics YOLOv8 [10], yang mendukung pendekatan *anchor-free detection* guna meningkatkan efisiensi deteksi. Hasilnya berupa model yang mampu mengenali dan mengklasifikasikan objek sampah secara otomatis berdasarkan citra masukan.

E. Evaluasi Model

Evaluasi model dilakukan untuk mengetahui seberapa akurat dan efektif model YOLOv8 dalam mengenali objek setelah melalui tahap pelatihan untuk mengidentifikasi dua kelas utama, yaitu sampah organik dan sampah anorganik. Pengujian dilakukan menggunakan *validation set* dan *testing set* yang telah dipisahkan dari data pelatihan guna memastikan hasil yang obyektif dan bebas dari *data leakage* [13]. Metrik utama yang digunakan dalam penelitian ini meliputi *Precision*, *Recall*, dan *mAP* (*mean Average Precision*) pada dua ambang batas yaitu *mAP@0.5* dan *mAP@0.5:0.95*. Metrik-metrik ini banyak digunakan dalam penelitian deteksi objek modern karena memberikan gambaran yang komprehensif tentang akurasi dan keandalan model dalam berbagai kondisi [14].

Precision menunjukkan seberapa banyak prediksi positif yang benar-benar sesuai objek sebenarnya, sedangkan *Recall* mengukur seberapa banyak objek sebenarnya yang berhasil dideteksi oleh model. Kedua metrik ini dirumuskan sebagai berikut :

$$Precision = TP / (TP + FP) \quad (1)$$

$$Recall = TP / (TP + FN) \quad (2)$$

dengan *TP* (True Positive) sebagai prediksi yang benar sepenuhnya terhadap objek yang ada, *FP* (False Positive) adalah prediksi yang salah terhadap objek yang sebenarnya tidak ada, dan *FN* (False Negative) sebagai total objek yang tidak teridentifikasi oleh model. Hubungan antara *Precision* dan *Recall* memberikan dasar bagi penilaian keseimbangan performa deteksi yang baik, sebagaimana diterapkan pula dalam penelitian-penelitian YOLOv8 terkini [15], [16].

Dalam menentukan apakah hasil deteksi dianggap benar (*True Positive*) digunakan ukuran *Intersection over Union* (IoU), yaitu rasio antara luas irisan (*intersection*) dan luas gabungan (*union*) antara *bounding box* prediksi dan *bounding box* sebenarnya. Nilai IoU berada diantara 0 hingga 1, dimana angka yang lebih tinggi menunjukkan sejauh mana hasil prediksi cocok dengan ukuran dan posisi objek sebenarnya.

Evaluasi performa model dilakukan melalui *mean Average Precision* (mAP), yang memberikan ringkasan komprehensif terhadap kualitas deteksi untuk semua kategori. Nilai mAP diturunkan dari *Average Precision* (AP), yaitu ukuran yang dihitung berdasarkan luas area kurva *Precision-Recall*. Formulasi matematisnya disajikan pada persamaan berikut.



$$AP = \left[\int_0^1 P(R) dR \right], \quad mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3)$$

dengan N menunjukkan jumlah kelas. Dalam penelitian ini terdapat dua kelas, yaitu organik dan anorganik. Pada tahap evaluasi, penelitian ini menggunakan dua ukuran mAP untuk memperoleh gambaran performa model secara lebih menyeluruh. $mAP@0.5$ digunakan untuk menilai akurasi deteksi pada satu nilai ambang *Intersection over Union* (IoU), sedangkan $mAP@0.5:0.95$ memberikan evaluasi yang lebih ketat karena mempertimbangkan sejumlah ambang IoU dari 0.5 hingga 0.95. Penggunaan kedua metrik ini sejalan dengan standar pengujian yang umum diterapkan pada dataset COCO [16], [17].

Nilai-nilai evaluasi tersebut menggambarkan performa model secara keseluruhan. *Precision* yang tinggi menunjukkan seberapa baik model dapat mengurangi angka deteksi palsu (*false positive*), sementara itu *Recall* yang

besar menunjukkan kemampuan model untuk menemukan sebagian besar objek yang tersedia. Nilai mAP yang mendekati 1 menunjukkan performa deteksi yang sangat baik dan konsisten di seluruh kelas, sebagaimana disimpulkan juga oleh beberapa studi terkini yang menguji varian YOLOv8 untuk berbagai aplikasi deteksi objek [14].


Hasil evaluasi yang diperoleh dari pengujian ini kemudian dianalisis lebih lanjut pada bab 3 untuk menilai bagaimana model YOLOv8 mampu mendeteksi dan mengklasifikasikan jenis sampah dengan akurasi yang tinggi dan efisiensi komputasi yang baik. Selain itu, analisis hasil juga dilakukan melalui *confusion matrix* dan *precision-recall curve* untuk memahami pola kesalahan deteksi antar kelas. Visualisasi ini membantu mengidentifikasi kelas yang sering tertukar serta mendeteksi potensi *underfitting* atau *overfitting* selama proses pelatihan.

3. Hasil dan Pembahasan

1. Hasil Pelatihan Model

Pelatihan pada penelitian ini memanfaatkan varian YOLOv8n, yaitu model berukuran kecil dalam keluarga YOLO yang dikembangkan oleh Ultralytics. Arsitekturnya yang ringan memungkinkan proses inferensi berlangsung cepat, sehingga cocok untuk kebutuhan deteksi objek dengan latensi rendah. Model dilatih selama 100 *epoch* menggunakan konfigurasi utama berupa ukuran citra

640×640 piksel, *batch size* 32, serta *initial learning rate* 0,01 sebagai nilai awal pembelajaran. Parameter *patience* ditetapkan selama 15 *epoch* untuk mengatur mekanisme *early stopping*. Seluruh proses pelatihan dijalankan pada GPU (Graphics Processing Unit) guna mempercepat konvergensi. Dataset yang digunakan terdiri dari 3.169 citra, dengan 2.018 citra beranotasi dalam format COCO, mencakup dua kelas objek yaitu sampah organik (947 anotasi) dan sampah anorganik (1.071 anotasi).



Gambar 2. Hasil Pelatihan Model YOLOv8

Grafik hasil pelatihan yang ditampilkan pada Gambar 2 menunjukkan penurunan konsisten pada *training loss* dan *validation loss* hingga mencapai titik stabil pada sekitar *epoch* ke-70, yang menandakan model berhasil belajar tanpa indikasi *overfitting*. Nilai *precision* dan *recall* meningkat stabil hingga mendekati 1,0, sementara $mAP50$ dan $mAP50-95$ meningkat signifikan dan mendekati konvergensi mencapai sekitar 0,98 pada akhir pelatihan [19]. Hasil tersebut mengindikasikan bahwa model YOLOv8n mampu mengenali dan membedakan kedua kelas objek secara efektif dengan akurasi tinggi. Tren metrik yang stabil menunjukkan konvergensi model tercapai dengan baik.

2. Evaluasi Model

Setelah proses pelatihan selesai selama 100 *epoch*, performa model dinilai melalui serangkaian pengujian pada data validasi yang tidak digunakan selama training. Evaluasi dilakukan untuk melihat bagaimana model merespons data yang tidak terlibat selama proses pelatihan, sehingga dapat dinilai kemampuan generalisasinya dalam mendeteksi sampah organik dan anorganik. Pengukuran performa dilakukan menggunakan Precision dan Recall untuk menggambarkan keseimbangan antara akurasi dan kelengkapan deteksi, serta mAP baik pada $mAP@0.5$ maupun $mAP@0.5-0.95$ untuk menilai kualitas prediksi pada berbagai ambang *Intersection over Union* (IoU).

Pendekatan ini memberikan gambaran yang lebih menyeluruh mengenai konsistensi model dalam menghadapi variasi data.

```
Validating /content/runs_yolo/train/weights/best.pt...
Ultralytics 8.3.222 Python-3.12.12 torch-2.8.0+cu126 CUDA:0 (Tesla T4, 15095MiB)
Model summary (fused): 72 layers, 3,006,038 parameters, 0 gradients, 8.1 GFLOPs
Class      Images  Instances  Box(P)      R      mAP50  mAP50-95): 100% 10/10 1.3it/s 7.8s
all         633      660        0.968      0.97   0.986   0.922
Sampah Anorganik 323      350        0.945      0.941  0.977   0.855
Sampah Organik  310      310        0.991      1.000  0.995   0.988
Speed: 0.2ms preprocess, 2.2ms inference, 0.0ms loss, 4.7ms postprocess per image
Results saved to /content/runs_yolo/train
```

Gambar 3. Hasil Evaluasi Model YOLOv8

Berdasarkan hasil validasi yang ditunjukkan pada Gambar 3, model YOLOv8 menunjukkan performa yang sangat baik dengan nilai mean Average Precision (mAP) yang tinggi. Metrik evaluasi yang digunakan mencakup beberapa aspek penting seperti *Precision* (P),


Recall (R), *mAP* pada ambang *IoU* 0.5 (mAP50), serta rata-rata *mAP* pada berbagai ambang *IoU* dari 0.5 hingga 0.95 (mAP50-95). Hasil lengkap evaluasi terlihat pada Tabel 1 berikut :

Tabel 1 Hasil Evaluasi Model

Kelas	Precision	Recall	mAP50	mAP50-95
Sampah Anorganik	0.945	0.941	0.977	0.855
Sampah Organik	0.991	1.000	0.995	0.988
Rata-rata (All)	0.968	0.970	0.986	0.922

Nilai *Precision* rata-rata sebesar 0.968 menunjukkan bahwa Sebagian besar prediksi yang dilakukan model bersifat benar (minim false positive), sementara nilai *Recall* sebesar 0.970 menandakan kemampuan model yang baik dalam mengenali hampir seluruh objek yang ada dalam citra (low false negative). Selain itu, nilai *mAP50* sebesar


0.986 menunjukkan bahwa pada ambang *IoU* 0.5, model dapat melakukan deteksi dengan akurasi sangat tinggi. Nilai *mAP50-95* sebesar 0.922 memperkuat bukti bahwa model tetap konsisten dalam mendeteksi objek pada berbagai tingkat tumpang tindih antara prediksi dan ground truth.



Gambar 4. Precision-Recall Curve

Gambar 4 menyajikan kurva *Precision-Recall* sebagai indikator stabilitas prediksi model. Variasi nilai pada kurva menunjukkan bagaimana model mempertahankan presisi sekaligus tetap sensitif terhadap objek yang terdeteksi pada berbagai *threshold*. Kurva yang cenderung

mendekati sudut kanan atas menandakan bahwa model memiliki keseimbangan optimal antara *false positive* dan *false negative*, menandakan deteksi yang stabil untuk kedua kelas objek [18].



Gambar 5. Confusion Matrix Model YOLO

Sebagai tambahan, Gambar 5 menyajikan *confusion matrix* yang menggambarkan pola prediksi model terhadap kedua kelas sampah. Nilai diagonal yang dominan menunjukkan bahwa sebagian besar objek berhasil diidentifikasi dengan benar, yakni 337 sampah anorganik dan 310 sampah organik. Pada sisi kesalahan prediksi, *false negative* terbesar terjadi pada kelas Anorganik, di mana 36 sampel anorganik terklasifikasi sebagai organik. Sebaliknya, *false positive* terbesar muncul pada kelas Organik, meskipun jumlahnya sangat kecil, yaitu hanya satu sampel yang salah dikenali sebagai anorganik. Selain itu, terdapat 13 kasus di mana objek tidak terdeteksi dan terbaca sebagai background. Pola kesalahan ini menunjukkan bahwa karakter visual tertentu pada sampah anorganik lebih mudah tertukar dengan kelas organik, terutama ketika bentuk atau teksturnya serupa, sementara model relatif stabil dalam membedakan sampah organik.


Secara keseluruhan, performa model YOLOv8 dapat dikategorikan sangat baik untuk tugas deteksi objek sampah. Kelas “Sampah Organik” memiliki nilai *Recall* sempurna (1.000), yang menunjukkan bahwa seluruh objek pada kelas ini berhasil terdeteksi oleh model. Sementara itu, kelas “Sampah Anorganik” memiliki

sedikit penurunan nilai *Recall* (0.941), yang dapat disebabkan oleh variasi bentuk, warna, atau kondisi pencahayaan yang lebih kompleks dibandingkan kelas organik.

Hasil ini menunjukkan bahwa model YOLOv8 telah mampu mempelajari fitur visual dengan baik, serta memiliki kemampuan generalisasi yang kuat terhadap data uji. Evaluasi ini membuktikan bahwa pendekatan YOLOv8 efektif dalam mendeteksi dan mengklasifikasikan jenis sampah secara akurat dan efisien.

3. Visualisasi Hasil Deteksi

Bagian ini menampilkan hasil visual dari proses deteksi objek menggunakan model YOLO yang telah dilatih. Tujuan visualisasi ini adalah untuk memperlihatkan kemampuan model dalam mengenali dan mengklasifikasikan objek sampah pada citra uji. Hasil deteksi ditunjukkan dengan bounding box berwarna yang mengelilingi objek serta label kelas yang teridentifikasi. Berdasarkan hasil visual pada Gambar 6, model YOLO mampu mendeteksi objek dengan cukup akurat, terutama pada objek berukuran sedang dan besar. Deteksi pada objek kecil terkadang masih kurang presisi, terutama ketika terdapat tumpang tindih antar objek atau pencahayaan yang tidak merata.



Gambar 6. Contoh Hasil Deteksi Objek Sampah

Secara keseluruhan, hasil visualisasi ini menunjukkan bahwa model YOLO telah berhasil mengenali objek sesuai dengan kelas yang telah didefinisikan pada dataset. Keluaran bounding box yang rapat terhadap objek menunjukkan bahwa model memiliki kemampuan lokalisasi yang baik, meskipun masih terdapat potensi peningkatan akurasi pada kondisi pencahayaan ekstrem atau objek dengan bentuk yang kurang jelas.

4. Pembahasan

Hasil evaluasi menunjukkan bahwa model YOLOv8n yang dilakukan dalam penelitian ini mencapai performa yang sangat baik: $Precision = 0,968$, $Recall = 0,970$, $mAP50 = 0,986$, $mAP50-95 = 0,922$. Nilai-nilai ini menunjukkan bahwa model mampu mengenali dan mengklasifikasikan objek sampah (organik dan anorganik) dengan akurasi tinggi serta minim kesalahan.

Kinerja model pada penelitian ini menunjukkan peningkatan dibandingkan salah satu studi yang menerapkan YOLOv8 pada aplikasi Android untuk klasifikasi sampah. Studi tersebut melaporkan precision sekitar 0,81 dan recall 0,61 dengan jumlah data dan jumlah epoch pelatihan yang relatif lebih kecil. Perbedaan performa ini mengindikasikan bahwa cakupan dataset yang lebih besar dan proses pelatihan yang lebih intensif berkontribusi pada hasil deteksi yang lebih stabil dalam penelitian ini [20]. Sedangkan penelitian oleh Inorganik Waste Detection Application Using Smart Computing Technology with YOLOv8 Method mendapatkan precision 0,9963, recall 0,9653 untuk deteksi lima kategori sampah anorganik, dengan akurasi total $\sim 0,99$ [21].

Meskipun demikian, terdapat aspek yang memerlukan perhatian lebih lanjut. Nilai $mAP50-95$ untuk kelas anorganik berada pada 0,855, yang menunjukkan bahwa deteksi objek kelompok ini masih mengalami penurunan performa relatif terhadap kelas organik yang mencapai 0,988. Ini kemungkinan

akibat variasi bentuk, warna dan ukuran objek anorganik. Fenomena semacam ini juga dilaporkan oleh penelitian lain yang menggunakan detector YOLO pada lingkungan nyata [22].

4. Kesimpulan

Penelitian ini menunjukkan bahwa penerapan algoritma YOLOv8n dalam mendeteksi dan mengklasifikasikan objek sampah organik serta anorganik dapat menunjukkan kinerja yang luar biasa dengan nilai $Precision$ sebesar 0,968, $Recall$ sebesar 0,970, $mAP@0,5$ mencapai 0,986, dan $mAP@0,5:0,95$ sebesar 0,922. Hasil ini menunjukkan bahwa model memiliki performa yang sangat baik, mampu mengenali dan membedakan dua jenis sampah secara akurat dan efisien. Proses pelatihan juga menunjukkan konvergensi yang stabil tanpa indikasi *overfitting*, yang menandakan bahwa model mampu belajar secara efektif dari dataset yang digunakan. Meskipun demikian, kinerja deteksi pada kelas sampah anorganik masih sedikit lebih rendah dibandingkan dengan kelas organik, diduga akibat variasi bentuk, warna, serta pencahayaan pada objek yang lebih kompleks. Temuan ini memperkuat potensi YOLOv8 sebagai pendekatan *real-time object detection* yang dapat dimanfaatkan untuk mendukung sistem pengelolaan sampah cerdas (smart waste management) di Indonesia.

Sebagai tindak lanjut, penelitian mendatang disarankan untuk memperluas jumlah dan variasi dataset terutama pada kelas sampah organik agar model memiliki kemampuan generalisasi yang lebih kuat terhadap berbagai kondisi lingkungan nyata, seperti pencahayaan ekstrem dan latar belakang yang kompleks. Selain itu, pengembangan lebih lanjut dapat mencakup penambahan kategori sampah baru, seperti plastik, logam, kertas, dan kaca, agar sistem lebih adaptif terhadap kebutuhan klasifikasi multiobjek di lapangan. Mengintegrasikan model deteksi dengan

perangkat IoT atau aplikasi mobile memungkinkan implementasi inferensi di sisi edge, sehingga proses identifikasi dapat dilakukan langsung di area pembuangan atau fasilitas daur ulang tanpa membutuhkan transmisi data berulang ke server. Di sisi lain, eksperimen menggunakan arsitektur model lain seperti *EfficientDet*, *RetinaNet*, atau *Faster R-CNN* dapat dilakukan untuk mengevaluasi keseimbangan antara akurasi dan efisiensi komputasi. Terakhir, penelitian di masa depan juga perlu meninjau aspek efisiensi energi dan kebutuhan sumber daya komputasi agar sistem deteksi ini dapat diterapkan pada perangkat dengan kemampuan terbatas, seperti edge device atau embedded system, sehingga mendukung penerapan nyata teknologi kecerdasan buatan dalam pengelolaan sampah yang berkelanjutan.

5. Daftar Pustaka

- [1] R. Puspita, "KLHK: Jumlah Timbunan Sampah di Indonesia Capai 29,8 Juta Ton pada 2021," 27 September. Accessed: Apr. 29, 2025. [Online]. Available: <https://news.republika.co.id/berita/riv7wa428/klhk-jumlah-timbunan-sampah-di-indonesia-capai-298-juta-ton-pada-2021>
- [2] P. Rainer, "Alasan Separuh Masyarakat RI Tidak Memilah Sampah," 22 Agustus. Accessed: Apr. 29, 2025. [Online]. Available: <https://data.goodstats.id/statistic/alasan-separuh-masyarakat-ri-tidak-memilah-sampah-5Dm7e>
- [3] D. S. Al-Fajri, "Mereka yang Tidak Memilah Sampah: 71,3% Merasa Merepotkan dan Bukan Tanggung Jawab," 30 November. Accessed: Apr. 29, 2025. [Online]. Available: <https://goodstats.id/article/mereka-yang-tidak-memilah-sampah-67-3-merasa-merepotkan-dan-bukan-sebuah-tanggung-jawab-OgWBK>
- [4] H. Khalid, "Buruknya Kebiasaan Buang Sampah Masyarakat Indonesia." Accessed: Nov. 18, 2025. [Online]. Available: <https://environment-indonesia.com/buruknya-kebiasaan-buang-sampah-masyarakat-indonesia/>
- [5] B. Prasetyo and N. Pratiwi, "Deteksi sampah organik dan anorganik menggunakan model yolov8," vol. 10, no. 1, pp. 494–506, 2025.
- [6] Y. Arvio, D. T. Kusuma, I. B. Sangadji, and S. Karmila, "Aplikasi Sistem Deteksi Sampah Organik dan Non Organik Menggunakan Algoritma YOLO V8," 2023. [Online]. Available: <https://snekti.jurnal-puslitbangpln.id/submit/index.php/snekti2023/article/view/265>
- [7] M. Fuchs, "The Data Science Process (CRISP-DM)," 21 Agustus. Accessed: Oct. 31, 2025. [Online]. Available: <https://michael-fuchs-python.netlify.app/2020/08/21/the-data-science-process-crisp-dm/>
- [8] Ultralytics, "Brief summary of YOLOv8 model structure," 10 January. Accessed: Oct. 31, 2025. [Online]. Available: <https://github.com/ultralytics/ultralytics/issues/189>
- [9] Z. Piao, J. Wang, L. Tang, B. Zhao, and S. Zhou, "Anchor-Free Object Detection with Scale-Aware Networks for Autonomous Driving," pp. 1–15, 2022.
- [10] B. Zhao, Q. Cui, R. Song, Y. Qiu, and J. Liang, "Decoupled Knowledge Distillation," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2022-June, pp. 11943–11952, 2022, doi: 10.1109/CVPR52688.2022.01165.
- [11] Ultralytics, "Ultralytics/ultralytics – Ultralytics YOLO." Accessed: Oct. 31, 2025. [Online]. Available: <https://github.com/ultralytics/ultralytics>
- [12] J. Terven, D. M. Córdova-Esparza, and J. A. Romero-González, "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS," *Mach. Learn. Knowl. Extr.*, vol. 5, no. 4, pp. 1680–1716, 2023, doi: 10.3390/make5040083.
- [13] IBM, "Data Leakage in Machine Learning." Accessed: Nov. 11, 2025. [Online]. Available: <https://www.ibm.com/think/topics/data-leakage-machine-learning>
- [14] A. Megantara and E. Utami, "Object Detection Using YOLOv8: A Systematic Review," vol. 14, pp. 1186–1193, 2025.
- [15] J. Bento, T. Paixão, and A. B. Alvarez, "Performance Evaluation of YOLOv8, YOLOv9, YOLOv10, and YOLOv11 for Stamp Detection in Scanned Documents," 2025.
- [16] G. Yao, S. Zhu, L. Zhang, and M. Qi, "HP-YOLOv8: High-Precision Small Object Detection Algorithm for Remote Sensing Images HP-YOLOv8: High-Precision Small Object Detection," 2024, doi: 10.20944/preprints202406.1963.v1.
- [17] Z. Han, Y. Cai, A. Liu, Y. Zhao, and C. Lin, "MS-YOLOv8-based object detection method for pavement diseases," *Sensors*, vol. 24, no. 4569, 2024.
- [18] C. Consortium, "COCO (Common Objects in Context) dataset." Accessed: Nov. 01, 2025. [Online]. Available: <https://cocodataset.org/#home>
- [19] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, "YOLOv4: Optimal Speed and Accuracy of Object Detection," 2020, [Online]. Available: <http://arxiv.org/abs/2004.10934>
- [20] M. R. Ridha, S. Syafrijon, Y. Hendriyani, and A. Hadi, "Implementasi Model Yolov8 untuk Deteksi Jenis Sampah Organik dan Anorganik Berbasis Android," *Abdimas Indones. J.*, vol. 5, no. 1, pp. 419–426, 2025, doi: 10.59525/aij.v5i1.655.
- [21] Y. Arvio, D. T. Kusuma, and I. BM Sangadji, "Inorganic Waste Detection Application Using



Smart Computing Technology with YOLOv8 Method,” *Sinkron*, vol. 8, no. 4, pp. 2389–2396, 2024, doi: 10.33395/sinkron.v8i4.14117.

[22] A. S. J, J. S. R, R. V. M, and M. P. G, “Real-Time Organic And Inorganic Object Detection Using Yolo Model,” pp. 1968–1970, 2025.

