

Pendeteksian dan Klasifikasi Sampah pada Bank Sampah Berbasis Web Menggunakan YOLOv11

Marsyanda Salsa Nabila ¹, Herlawati Herlawati ^{1,*}, Agus Hidayat ¹

* Korespondensi: e-mail: herlawati@ubharajaya.ac.id

¹ Informatika; Fakultas Ilmu Komputer; Universitas Bhayangkara Jakarta Raya, Jl. Perjuangan No. 81, Marga Mulya, Bekasi Utara, Bekasi, Jawa Barat, 17143, telp/fax: (021) 88955882; e-mail: 202110715069@mhs.ubharajaya.ac.id, herlawati@ubharajaya.ac.id, agus.hidayat@dsn.ubharajaya.ac.id

Submitted : 24 Maret 2025
Revised : 15 April 2025
Accepted : 07 Mei 2025
Published : 30 Mei 2025

Abstract

The problem of poorly managed household waste management can increase the burden on the environment and reduce the effectiveness of recycling. Waste banks in general still rely on manual systems in sorting waste which is prone to errors and requires more labor. This research aims to develop a web-based waste detection and classification system using the You Only Look Once (YOLO) version 11 yolov11n (nano) method. The research method includes downloading a secondary dataset named R1 Test from the Roboflow Universe platform, collecting primary datasets from internet scraping and manual shooting which resulted in a total of 27,400 litter images with 9 (nine) different types, namely bottle, cans, cardboard, cup, foil, food, paper, paper_bag, and plastic. The results show that the yolov11n model is able to detect objects with sufficient accuracy and light computational resources by producing a precision value of 0.917, recall of 0.890, mAP50 of 0.932% and mAP50-95 of 0.758% in all classes. The best model results obtained are integrated into the web using the flask framework.

Keywords: Object Detection, Waste Bank, Waste Classification, Web, You Only Look Once (YOLO)

Abstrak

Permasalahan pengelolaan sampah rumah tangga yang tidak terkelola dengan baik dapat meningkatkan beban lingkungan dan mengurangi efektivitas daur ulang. Bank sampah umumnya masih mengandalkan sistem manual dalam pemilahan sampah, yang rentan terhadap kesalahan dan membutuhkan lebih banyak tenaga kerja. Penelitian ini bertujuan mengembangkan sistem pendeteksian dan klasifikasi sampah berbasis web menggunakan metode You Only Look Once (YOLO) versi 11 jenis yolov11n (nano). Metode penelitian meliputi pengunduhan dataset sekunder bernama R1 Test dari platform Roboflow universe, pengumpulan dataset primer dari scraping internet dan pemotretan manual, yang menghasilkan sejumlah 27.400 gambar sampah dengan 9 (sembilan) jenis berbeda yaitu *bottle*, *cans*, *cardboard*, *cup*, *foil*, *food*, *paper*, *paper_bag* dan *plastic*. Hasil penelitian menunjukkan bahwa model yolov11n mampu mendeteksi objek cukup akurat dan sumber daya komputasi yang ringan dengan menghasilkan nilai *precision* sebesar 0.917, *recall* sebesar 0.890, mAP50 sebesar 0.932% dan mAP50-95 sebesar 0.758% pada seluruh kelas. Hasil model terbaik yang didapatkan diintegrasikan ke dalam web menggunakan framework flask.

Kata kunci: Bank Sampah, Klasifikasi Sampah, Object Detection, Web, You Only Look Once (YOLO)

1. Pendahuluan

Masalah pengelolaan sampah telah berkembang menjadi isu global yang kian hari semakin mendesak. Menurut data terbaru dari Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) Kementerian Lingkungan Hidup dan Kehutanan (KLHK), pada tahun 2024, 314 kabupaten/kota di Indonesia telah menghasilkan 33,820,687.54 ton sampah dan 40,2% atau sekitar 13,596,587.77 ton merupakan sampah yang tidak terkelola dengan baik, serta sumber sampah yang dihasilkan sekitar 53,72% nya berasal dari sampah rumah tangga (Kementerian Lingkungan Hidup dan Kehutanan (KLHK), 2024). Selain itu, menurut laporan *World Bank* tahun 2018, produksi sampah di seluruh dunia diperkirakan akan meningkat 3,40 miliar ton pada tahun 2050 (World Bank, 2018). Masalah-masalah tersebut mengindikasikan bahwa kesulitan pengelolaan dan pemilahan sampah akan semakin besar.

Menurut Rahman et al., 2022, berdasarkan laporan EUROSTAT menunjukkan perlunya pengelolaan sampah rumah tangga yang tepat dalam proses daur ulang (Rahman et al., 2022). Pengelolaan dan pemilahan sampah rumah tangga yang tidak tepat dapat mencemari sampah daur ulang, membatasi efektivitas daur ulang, meningkatkan limbah TPA, dan berkontribusi terhadap kerusakan lingkungan dan penipisan sumber daya seiring dengan meningkatnya produksi sampah global (Arishi, 2025). Oleh karena itu, bank sampah merupakan strategi yang tepat untuk memberikan solusi dalam mengurangi sampah yang tidak terkelola, dengan menerapkan konsep 3R yaitu *reduce*, *reuse*, dan *recycle*.

Namun, salah satu tantangan terbesar dalam fungsi bank sampah saat ini adalah kurangnya teknologi yang memadai untuk pengelolaan sampah secara otomatis. Bank sampah saat ini masih melakukan pendeteksian dan klasifikasi secara manual yang menyebabkan kerentanan terhadap kesalahan, membutuhkan banyak tenaga kerja, dan memakan waktu, terutama saat terjadi pergantian petugas. Selain itu, masih minimnya pemahaman masyarakat dalam memilah jenis sampah yang sesuai aturan bank sampah. Akibatnya, hal ini menyebabkan efisiensi pengelolaan sampah menjadi rendah sehingga menghambat optimalisasi program daur ulang.

Metode *You Only Look Once (YOLO)* telah banyak digunakan dalam berbagai penelitian terkait deteksi objek, yang terkenal dengan kecepatan dan ketepatannya dalam mengidentifikasi berbagai jenis objek dalam citra digital. Beberapa penelitian sebelumnya menunjukkan bahwa model *You Only Look Once (YOLO)* memiliki kinerja akurasi dan kecepatan pelatihan yang lebih baik dibanding model konvensional lainnya (Justam et al., 2024)(Kunwar et al., 2025). *You Only Look Once (YOLO)* telah terbukti unggul dalam berbagai aspek, diantaranya memiliki kecepatan tinggi dengan presisi dua kali lebih baik dibandingkan sistem *real-time* lainnya, *You Only Look Once (YOLO)* juga mampu mendeteksi objek dengan lebih akurat karena memperhitungkan keseluruhan gambar secara global, serta kemampuan generalisasinya juga lebih unggul dibandingkan metode deteksi objek lainnya sehingga lebih adaptif terhadap perubahan domain atau variasi data yang tidak terduga (Redmon et al., 2016). Selama perkembangannya, *You Only Look Once (YOLO)* telah berevolusi dari versi

pertamanya pada tahun 2015, hingga versi 11 saat ini yang mulai digunakan pada tahun 2024 (Hidayatullah et al., 2025).


You Only Look Once (YOLO) telah digunakan oleh beberapa penelitian sebelumnya yang melakukan identifikasi berbagai jenis sampah dengan variasi versi *You Only Look Once (YOLO)* yang berbeda, seperti *YOLOv5* (Yasiri et al., 2025)(Karyanto et al., 2024), *YOLOv8* (Vieri et al., 2024)(Visen & Charibaldi, 2025), *YOLOv9* (Adriansyah & Putra, 2025), dan *YOLOv11* (Aprilla et al., 2024), yang menunjukkan bahwa *You Only Look Once (YOLO)* mampu mengidentifikasi objek sampah dengan performa yang baik. Namun, sebagian besar penelitian tersebut hanya berfokus pada jenis sampah tertentu tanpa mencakup variasi yang lebih luas dan lebih banyak berfokus pada deteksi sampah di lingkungan umum tanpa mencakup bank sampah sebagai lingkup pengelolaan sampah masyarakat. Selain itu, sebagian besar penelitian masih terbatas pada implementasi model deteksi sampah yang masih dilakukan secara lokal tanpa adanya integrasi berbasis *web*. Oleh karena itu, penelitian ini bertujuan untuk menerapkan metode *You Only Look Once (YOLO)* versi 11 dalam melakukan pendeteksian dan klasifikasi sampah berbasis *web* pada Bank Sampah.

2. Metode Penelitian

Penelitian ini menggunakan metode *Cross Industry Standard Process for Data Mining (CRISP-DM)* sebagai acuan dalam proses pengolahan data untuk melakukan pendeteksian dan Klasifikasi Sampah dan *You Only Look Once (YOLO)* untuk algoritma pemodelan deteksi objek.

2.1. Cross Industry Standard Process for Data Mining (CRISP-DM)

Cross Industry Standard Process for Data Mining (CRISP-DM) diperkenalkan sejak tahun 1996 yang digunakan sebagai kerangka kerja analisis industri untuk merancang strategi pemecahan masalah bisnis (Fitriana et al., 2022). Metodologi ini terdiri dari enam tahapan utama yang bersifat iteratif, sehingga dapat dilakukan berulang kali guna meningkatkan kinerja sistem berdasarkan hasil evaluasi (Schröer et al., 2021).




Sumber: (Martinez-Plumed et al., 2021)

Gambar 1. Tahapan CRISP-DM

2.2. You Only Look Once (YOLO)

You Only Look Once (YOLO) merupakan model berbasis *deep learning* yang digunakan dalam lingkup *object detection* dan dikembangkan pertama kali oleh Joseph Redmon pada tahun 2015 (Hidayatullah, 2023). Adapun cara kerja *You Only Look Once (YOLO)* dapat dilihat pada Gambar 2 berikut.



Sumber: (Redmon et al., 2016)

Gambar 2. Cara Kerja YOLO

Cara kerja metode *You Only Look Once (YOLO)* melibatkan pembagian dua citra input ke dalam *grid* yang berukuran $S \times S$. Masing-masing sel di dalam *grid* ini bertugas untuk menghasilkan prediksi nilai *confidence* serta sejumlah *bounding box*. Apabila tidak terdapat objek di dalam suatu sel, maka nilai *confidence* yang dihasilkan akan bernilai nol. Setelah seluruh nilai *confidence* diperoleh untuk setiap sel, maka nilai-nilai ini kemudian dibandingkan dengan *Intersection Over Union (IoU)* guna menentukan *bounding box* prediksi terbaik untuk setiap kelas yang terdeteksi dengan perhitungan (Liu et al., 2020):

$$\text{Confidence} = \text{Pr}(\text{Object}) \times \text{IoU}(\text{GT}, \text{pred}) \quad (1)$$

Pr = Probability

IoU = Intersection Over Union (IoU)

GT = Ground Truth

Pred = Prediction

3. Hasil dan Pembahasan

Penelitian menggunakan metode *Cross Industry Standard Process for Data Mining (CRISP-DM)* dan algoritma *You Only Look Once (YOLO)* dalam proses pemodelan yang melibatkan beberapa alur proses hingga mendapatkan hasil terbaik yang diterapkan dalam sistem pendeteksian dan klasifikasi sampah pada bank sampah berbasis *web* dengan tujuan mengidentifikasi 9 (sembilan) jenis sampah secara informatif dan menjadi dasar dalam penerapan sistem dalam lingkup bank sampah.

Penelitian menggunakan gabungan antara dataset sekunder yang diperoleh dari platform *Roboflow universe* bernama R1 Test dengan dataset sekunder yang diperoleh dari *scraping* internet dan pemotretan manual untuk mendukung pendeteksian objek secara nyata.


Proses pemodelan dalam penelitian dilakukan dengan algoritma *You Only Look Once* (YOLO) jenis *yolov11n (nano)* dengan menggunakan perbandingan pembagian data sebesar 78:14:8 untuk pelatihan, validasi, dan pengujian. Evaluasi menunjukkan bahwa model *yolov11n* menghasilkan performa yang cukup baik dalam melakukan pendeteksian dan klasifikasi objek sampah yang selanjutnya model dengan evaluasi terbaik dipilih untuk diterapkan pada *web* menggunakan *framework flask* untuk melakukan deteksi dan klasifikasi sampah secara otomatis.

3.1. Bussiness Understanding

Penelitian ini bertujuan untuk membuat pendeteksian dan klasifikasi sampah berbasis *web* menggunakan metode *You Only Look Once* (YOLO) untuk mengotomatisasi proses pengelolaan sampah dan diharapkan dapat menjadi dasar pengadopsian teknologi dalam lingkup bank sampah secara khusus maupun lebih luas. Hasil dari penelitian ini dapat digunakan untuk menjadi sarana edukasi masyarakat dan membantu dalam proses pemilahan serta pendataan sampah berbasis teknologi.

3.2. Data Understanding

Dataset yang digunakan dalam penelitian ini diperoleh melalui dua sumber yaitu data sekunder dari platform *Roboflow universe* bernama R1 Test <https://universe.roboflow.com/recycal/r1-test> serta data primer dari *scraping* internet dan pemotretan manual menggunakan *handphone* seperti pada Gambar 3.



Sumber: Hasil Penelitian (2025)

Gambar 3. (a) Data Sekunder R1 Rest versi 15, (b) Data Primer

Data sekunder bernama R1 Test (a) terdiri dari 26.959 gambar dan 9 kelas berbeda yaitu *bottle*, *cans*, *cardboard*, *cup*, *foil*, *food*, *paper*, *paper_bag* dan *plastic*. Sedangkan data primer (b) yang digunakan terdiri dari 468 gambar dengan jumlah kelas yang sama dan dilakukan anotasi secara manual dalam platform *Roboflow universe*. Data-data tersebut diperoleh dengan cara pengunduhan dalam format zip melalui platform *roboflow universe*, kemudian dilakukan ekstraksi. Namun, saat ekstraksi data sekunder berlangsung terjadi "*filename too long error*" yang menyebabkan data berkurang sebagian kecil yaitu sebanyak 24 gambar dan label, akan tetapi kendala tersebut tidak berpengaruh secara signifikan terhadap

hasil. Selanjutnya, data-data tersebut dilakukan penggabungan secara manual di dalam folder train dan didapatkan total keseluruhannya menjadi sebanyak 27.403 gambar.

3.3. Data Preparation

Tahap *data preparation* dalam penelitian meliputi beberapa langkah diantaranya yaitu:

a. Pengecekan Anotasi

Tahap ini bertujuan untuk melakukan pengecekan atau identifikasi terkait anotasi *bounding box* pada dataset keseluruhan, apakah sudah merepresentasikan objek dan terseruktur dengan benar. Selain itu, tahap ini juga bertujuan untuk pengidentifikasian sementara terkait apakah ada objek yang teranotasi kurang tepat, apakah ada objek yang salah teranotasi dan apakah ada objek yang tidak teranotasi sama sekali.

b. Pengecekan Data Label Kosong

Tahap ini meliputi pengecekan dan penghapusan data yang tidak memiliki label atau tidak teranotasi dengan tujuan mempertahankan konsistensi anotasi tiap kelas. Detail pengecekan data label kosong ditunjukkan pada Gambar 4.

```

**Jumlah Data Sebelum Penghapusan:**
Train → Gambar: 21267, Label: 21264
Valid → Gambar: 3924, Label: 3924
Test → Gambar: 2212, Label: 2212

**Proses Penghapusan Gambar dengan Label Kosong...**

Gambar dengan label kosong di /content/R1 Test.v15i.yolov11/train/images: 3
Deleted image: /content/R1 Test.v15i.yolov11/train/images/plastic377_jpg.rf.14cf91a61b478fe5e836e5798712fc26.jpg
Deleted image: /content/R1 Test.v15i.yolov11/train/images/plastic-414-_JPG_jpg.rf.604eb5f3369878d88cedb8a3f3c5cda7.jpg
Deleted image: /content/R1 Test.v15i.yolov11/train/images/Image_20_jpg.rf.e6190ac9a5c3ae214a468430f84133ef.jpg
Gambar dengan label kosong di /content/R1 Test.v15i.yolov11/valid/images: 0
Gambar dengan label kosong di /content/R1 Test.v15i.yolov11/test/images: 0

**Jumlah Data Setelah Penghapusan:**
Train → Gambar: 21264, Label: 21264
Valid → Gambar: 3924, Label: 3924
Test → Gambar: 2212, Label: 2212

```

Sumber: Hasil Penelitian (2025)

Gambar 4. Hasil Pengecekan Data Label Kosong

Pada Gambar 4. ditemukan bahwa pada folder *train* terdapat tiga buah label kosong (tidak teranotasi) pada dua kelas *plastic* dan satu kelas *cup*, sehingga dilakukan penghapusan terhadap data label kosong tersebut dengan tujuan mempertahankan konsistensi anotasi kelas.

c. Identifikasi Pembagian dan Jumlah Data

Tahap ini meliputi pengidentifikasian jumlah pembagian data, distribusi kelas, hingga jumlah total data bersih yang akan digunakan dalam proses pelatihan data selanjutnya. Jumlah pembagian data dan total data bersih ditunjukkan pada Gambar 5.

 **Ringkasan Jumlah Data:** Train → Gambar: 21264, Label: 21264 Valid → Gambar: 3924, Label: 3924 Test → Gambar: 2212, Label: 2212	 **Total Data Keseluruhan:**  Total Gambar → 27400  Total Label → 27400
(a)	(b)

Sumber: Hasil Penelitian (2025)

Gambar 5. (a) Jumlah Pembagian Data, (b) Total Data Bersih

Pada Gambar 5. dapat diketahui bahwa perbandingan pembagian data (1) terbagi menjadi 78% (21.264 gambar dan label), 14% (3.924 gambar dan label) dan 8% (2.212 gambar dan label). Sedangkan total keseluruhan data menjadi sebanyak 27.400 gambar dan label.

d. Pengecekan Data Duplikat

Tahap ini bertujuan untuk mengetahui apakah terdapat lebih dari satu label atau kelas dalam satu gambar. Detail pengecekan data duplikat ditunjukkan pada Gambar 6.

Jumlah gambar dengan anotasi duplikat dalam /content/R1 Test.v15i.yolov11/train/labels: 6570
Jumlah gambar dengan anotasi duplikat dalam /content/R1 Test.v15i.yolov11/valid/labels: 1114
Jumlah gambar dengan anotasi duplikat dalam /content/R1 Test.v15i.yolov11/test/labels: 606

Sumber: Hasil Penelitian (2025)

Gambar 5. Hasil Pengecekan Data Duplikat

Berdasarkan Gambar 5, Dari hasil tersebut ditemukan bahwa terdapat data dengan label duplikat sebanyak 6.570 gambar pada data *train*, 1.114 gambar pada data *validation*, dan 606 gambar pada data *test*. Data dengan label duplikat tidak dilakukan penanganan penghapusan dikarenakan data tersebut dapat mendukung pendeteksian menggunakan *multiple prediction* (prediksi lebih dari satu kelas dalam satu gambar).

3.4. Modelling

Tahap *modelling* merupakan tahapan inti yang mencakup penerapan algoritma *You Only Look Once* (YOLO). Model yang digunakan dalam penelitian ini adalah YOLOv11n (*nano*) dengan pendekatan *transfer learning*, yang memungkinkan proses pelatihan lebih efisien dengan memanfaatkan bobot dari model yang telah dilatih sebelumnya dan kemudian diterapkan pada dataset baru dalam penelitian ini yaitu dataset R1 Test dari platform *Roboflow universe* dan dataset primer untuk pendeteksian dan klasifikasi 9 (sembilan) jenis sampah. Tahapan *modelling* mencakup beberapa langkah diantaranya yaitu:

a. Pengunduhan dan Impor *Library* Pemodelan

Tahap ini mencakup pengunduhan dan pemasangan *library* utama bernama *Ultralytics* dan pengimporan *library* pemodelan bernama YOLO dengan tujuan agar semua fungsi dan modul yang berkaitan dengan model YOLO dapat tersedia di lingkungan yang digunakan sehingga pengguna dapat memanfaatkan model YOLO secara langsung tanpa membangun algoritma dari awal.

b. Pengaturan *Hyperparameter*

Hyperparameter yang dipilih dan diuji dalam penelitian ini yang dilakukan secara bertahap untuk menilai evaluasi dari masing-masing kombinasi terhadap akurasi model dan performa pelatihan yang ditunjukkan pada Tabel 1.

Berdasarkan Tabel 1, penelitian ini melakukan beberapa percobaan pengaturan *hyperparameter* dengan tujuan mencari komposisi yang paling optimal. Pada semua percobaan, *batch size* diatur secara konstan sebesar 32 karena memiliki performa terbaik dan penggunaan memori yang cukup stabil.

Tabel 1. Pengaturan *Hyperparameter*


Batch	Epoch	Optimizer	Learning rate	Imgsz
32	10	AdamW	0.000769	640
32	15	AdamW	0.000769	640
32	20	AdamW	0.000769	640
32	25	AdamW	0.000769	640
32	30	AdamW	0.000769	640

Sumber: Hasil Penelitian (2025)

Ukuran input gambar distandarisasi sebesar 640×640 piksel untuk menyeimbangkan resolusi deteksi dan kecepatan model. Selanjutnya, adapun jumlah *epoch* yang divariasikan secara bertahap yang dimulai dari 10, 15, 20, 25, hingga 30 untuk mengevaluasi peningkatan kualitas model. Selain itu, *optimizer* dan *learning rate* terbaik yang digunakan dalam penelitian ini diatur secara *default* yang otomatis terpilih pada saat proses pelatihan.

c. Training Model

Tahap ini mencakup penerapan *hyperparameter* dan proses pelatihan yang melibatkan penggunaan *pre-trained model* yolov11n.pt yang dilatih ulang dengan dataset dalam penelitian ini agar performa deteksi objek menjadi lebih baik sesuai dengan kebutuhan penelitian. Hasil dari *training model* dapat ditunjukkan pada Gambar 6.



Sumber: Hasil Penelitian (2025)

Gambar 6. Training Result

Berdasarkan Gambar 6, kurva *training result* menunjukkan menunjukkan *loss* terhadap *Box Loss*, *Classification Loss*, dan *Distribution Focal Loss* yang menurun secara konsisten mulai *epoch* 10 hingga 30. Nilai *precision*, *recall*, *mAP50*, dan *mAP50-95* juga meningkat dengan pesat yang menunjukkan bahwa model telah menunjukkan performa yang cukup baik.

3.5. Evaluation

Setelah tahap *modelling* telah dilakukan, adapun proses evaluasi terhadap 9 (sembilan) kelas dengan metrik utama yang ditampilkan adalah *precision*, *recall*, dan *mean Average Precision* (mAP) yang terdiri dari *mAP50* dan *mAP50-95*. Ketiga metrik utama tersebut dapat didefinisikan sebagai berikut:

- a. *Precision* digunakan untuk mengukur tingkat ketepatan (presisi) dalam hasil pendeteksian objek. *Precision* dapat dihitung dengan persamaan sebagai berikut [34]:

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

Keterangan: TP = Nilai *True Positive* (TP)

FP = Nilai *False Positive* (FP)

- b. *Recall* digunakan untuk mengukur seberapa banyak objek (*ground truth*) yang dideteksi oleh sistem. *Recall* dapat dihitung dengan persamaan sebagai berikut [34]:

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

Keterangan: TP = Nilai *True Positive* (TP)

FP = Nilai *False Negative* (FN)

- c. *Mean Average Precision* (mAP) merupakan metrik pengukuran yang digunakan untuk menilai kinerja model deteksi objek. Nilainya berkisar antara 0 hingga 1, di mana semakin tinggi nilai tersebut, semakin baik performa model yang dihasilkan. *Mean Average Precision* (mAP) dihitung dengan mengambil rata-rata dari nilai *Average Precision* (AP) pada berbagai kelas objek (Hidayatullah, 2023) yang dapat dihitung dengan persamaan berikut:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

Keterangan: N = Jumlah kelas

AP_i = Nilai *Average Precision* (AP) untuk kelas ke-i


Metrik-metrik tersebut memberikan gambaran secara keseluruhan terkait performa akurasi model dalam mendeteksi objek dari berbagai kelas pada data yang belum pernah dilihat sebelumnya. Adapun detail hasil evaluasi dari percobaan *training* beberapa *hyperparameter* sebelumnya yang terbagi dalam Tabel 2.

Tabel 2. Hasil Evaluasi Penerapan Kombinasi *Hyperparameter*

Batch	Epoch	Optimizer	Learning rate	Imgsh	Precision	Recall	mAP50	mAP50-95
32	10	AdamW	0.000769	640	0.896	0.853	0.914	0.722
32	15	AdamW	0.000769	640	0.913	0.863	0.918	0.737
32	20	AdamW	0.000769	640	0.921	0.879	0.925	0.748
32	25	AdamW	0.000769	640	0.921	0.874	0.926	0.752
32	30	AdamW	0.000769	640	0.917	0.890	0.932	0.758

Sumber: Hasil Penelitian (2025)

Berdasarkan Tabel 2, dapat disimpulkan bahwa performa dan akurasi model terbaik ditunjukkan pada *epoch* ke 30 dengan detail pada Gambar 7.



```

Ultralytics 8.3.131 Python-3.11.12 torch-2.6.0+cu124 CUDA:0 (Tesla T4, 15095MiB)
YOLO11n summary (fused): 100 layers, 2,583,907 parameters, 0 gradients, 6.3 GFLOPs
val: Fast image access (ping: 0.0±0.0 ms, read: 1300.1±306.4 MB/s, size: 278.6 KB)
val: Scanning /content/R1 Test.v15i.yolov11/valid/labels.cache... 3924 images, 0 backgrounds, 0 corrupt: 100%
WARNING ⚠ Box and segment counts should be equal, but got len(segments) = 51, len(boxes) = 6375. To resolve

```

Class	Images	Instances	Box(P)	R	mAP50	mAP50-95
all	3924	6375	0.917	0.89	0.932	0.758
Bottle	1161	1501	0.947	0.943	0.976	0.835
Cans	972	1800	0.929	0.925	0.965	0.83
Cardboard	173	303	0.853	0.799	0.88	0.643
Cup	151	374	0.919	0.97	0.984	0.802
Foil	187	204	0.926	0.926	0.962	0.816
Food	81	278	0.922	0.895	0.95	0.733
Paper	290	404	0.888	0.77	0.799	0.672
Paper_Bag	696	1179	0.977	0.97	0.992	0.867
Plastic	214	332	0.891	0.815	0.88	0.623

Speed: 0.3ms preprocess, 3.8ms inference, 0.0ms loss, 1.4ms postprocess per image
Results saved to runs/detect/val
Learn more at <https://docs.ultralytics.com/modes/val>

Sumber: Hasil Penelitian (2025)


Gambar 7. Hasil Evaluasi Model

Berdasarkan Gambar 7, secara keseluruhan dapat terlihat bahwa model sudah sangat baik dalam mendeteksi sebagian besar objek dengan mencapai nilai *precision* sebesar 0.917, *recall* sebesar 0.890, mAP50 sebesar 0.932% dan mAP50-95 sebesar 0.758% pada seluruh kelas. Selain itu, performa masing-masing kelas juga sudah cukup baik meskipun masih memerlukan beberapa peningkatan lebih lanjut, terutama pada kelas *Paper*, *Plastic* dan *Cardboard*.

3.6. Deployment


Pada tahap *deployment*, sistem pendeteksian dan klasifikasi sampah telah berhasil diterapkan atau diimplementasikan dengan meliputi penerapan hasil terbaik model saat pelatihan bernama best.pt ke dalam *web* menggunakan bahasa pemrograman *python* dengan *framework Flask* serta melibatkan beberapa bahasa pemrograman pendukung lainnya untuk kesempurnaan antarmuka seperti *HyperText Markup Language (HTML)* untuk membangun struktur *web* dan konten, *Cascading Style Sheet (CSS)* untuk mengatur tampilan dan gaya visual, dan *JavaScript (JS)* untuk interaktivitas dan perilaku dinamis. *Web* ini dirancang dengan tujuan menjadi dasar adopsi teknologi pendeteksian dan klasifikasi sampah secara otomatis yang dapat memudahkan pengguna dalam melakukan identifikasi dan klasifikasi jenis sampah secara informatif dengan mengubah nama kelas ke dalam bahasa indonesia. Hasil Penerapan terdiri dari 3 menu berbeda diantaranya yaitu menu halaman utama, menu deteksi *real-time*, dan menu deteksi gambar. Detail menu halaman utama dilihat pada Gambar 8.

Berdasarkan Gambar 8, menu halaman utama menampilkan detail informasi terkait panduan atau mekanisme bank sampah dan informasi masing-masing jenis sampah. Selanjutnya, Menu deteksi *real-time* telah berhasil dibuat yang mendukung pendeteksian objek sampah secara *real-time* (langsung) dengan cara menunjukkan objek di hadapan kamera dan otomatis menampilkan hasil.



Sumber: Hasil Penelitian (2025)

Gambar 8. (a) Tampilan Atas Halaman Utama, (b) Tampilan Panduan dan Mekanisme Bank Sampah, (c)(d)(e) Tampilan Rincian Pemilihan Sampah




Sumber: Hasil Penelitian (2025)

Gambar 9. (a) Tampilan Awal Menu Deteksi *Real-time*, (b) Tampilan Hasil Deteksi *Real-time*

Detail menu deteksi *real-time* dapat dilihat pada Gambar 9. Tampilan menu deteksi *real-time* mendukung beberapa fitur diantaranya yaitu mulai kamera, hentikan deteksi untuk menutup kamera, reset untuk menghapus riwayat deteksi dan menutup kamera, dan unduh

data hasil deteksi dalam format csv. Menu selanjutnya yaitu menu deteksi gambar yang telah berhasil dibuat yang mendukung pendeteksian objek sampah dengan memasukkan gambar dengan cara mengunggah dan memprosesnya dan hasil akan tampil otomatis setelah diproses. Detail menu deteksi gambar dapat dilihat pada Gambar 10.



Sumber: Hasil Penelitian (2025)

Gambar 10. (a) Tampilan Awal Menu Deteksi Gambar, (b) Tampilan Hasil Deteksi Gambar

Pada Gambar 10, memiliki kemiripan beberapa fitur dengan menu sebelumnya, namun menu deteksi gambar mendukung fitur diantaranya unggah gambar, proses untuk memulai pendeteksian gambar, reset untuk menghapus riwayat deteksi dan memuat ulang dari awal, dan unduh data hasil deteksi dalam format csv.

4. Kesimpulan

Penerapan metode *You Only Look Once (YOLO)* terbukti efektif dalam melakukan pendeteksian dan klasifikasi objek sampah. Dari 9 (sembilan) jenis sampah berbeda, model *yolov11n* menunjukkan performa yang baik secara keseluruhan, dengan menghasilkan metrik evaluasi berupa nilai *precision* sebesar 0.917, *recall* sebesar 0.890, *mAP50* sebesar 0.932% dan *mAP50-95* sebesar 0.758. Meskipun demikian, akurasi pada kelas *Plastic*, *Cardboard*, dan *Paper* masih relatif lebih rendah dibandingkan kelas lainnya, yang diduga disebabkan oleh kemiripan visual antar kelas serta potensi *noise* dalam data latih. Kondisi ini merupakan tantangan umum dalam pendeteksian dan klasifikasi objek dengan karakteristik visual serupa. Hasil penelitian ini telah berhasil diterapkan ke dalam *web* menggunakan *framework flask* dan didukung oleh bahasa pemrograman lainnya yang menciptakan antarmuka sederhana yang informatif dan edukatif bagi masyarakat serta pihak bank sampah. Penelitian selanjutnya diharapkan untuk dapat mengeksplor dan mengembangkan model dengan versi yang lebih baik serta meningkatkan variasi dan keseimbangan dataset untuk kesempurnaan kualitas atau performa model.

Ucapan Terima Kasih

Peneliti menyampaikan apresiasi yang tulus kepada para reviewer atas kritik dan saran konstruktif yang telah membantu meningkatkan kualitas artikel ini. Ucapan terima kasih juga ditujukan kepada Universitas Bhayangkara Jakarta Raya atas segala bentuk dukungan yang

diberikan selama proses penelitian, baik berupa fasilitas, bimbingan, maupun kesempatan untuk mengembangkan riset ini. Segala kontribusi tersebut sangat berarti dalam mendukung kelancaran dan keberhasilan penelitian ini.

Daftar Pustaka

- Adriansyah, D., & Putra, M. P. K. (2025). Sistem Deteksi Objek Visual Sampah Organik Dan Anorganik Berbasis Algoritma YOLOv9. *Journal of Information System Research (JOSH)*, 6(2), 1321–1330. <https://doi.org/10.47065/josh.v6i2.6454>
- Aprilla, A., Prihartono, W., & Rohmat, C. L. (2024). Optimasi Model Klasifikasi Citra Sampah Daur Ulang dengan Algoritma YOLO11. *Jurnal Khatulistiwa Informatika*, 12(2), 92–97. <https://doi.org/10.31294/jki.v12i2.24646>
- Arishi, A. (2025). Real-time Household Waste Detection and Classification for Sustainable Recycling: A Deep Learning Approach. *Sustainability*, 17(5), 1–25. <https://doi.org/10.3390/su17051902>
- Fitriana, R., Habyba, A. N., & Febriani, E. (2022). *Data Mining dan Aplikasinya: Contoh Kasus di Industri Manufaktur dan Jasa*. Wawasan Ilmu. <https://books.google.co.id/books?id=9XGWEAAAQBAJ&printsec=frontcover&hl=id#v=onepage&q&f=false>
- Hidayatullah, P. (2023). *Buku Sakti Deep Learning Computer Vision Menggunakan YOLO untuk Pemula* (1st ed.). Stunning Vision AI Academy.
- Hidayatullah, P., Syakrani, N., Sholahuddin, M. R., Gelar, T., & Tubagus, R. (2025). YOLOv8 to YOLO11: A Comprehensive Architecture In-depth Comparative Review. *ArXiv Preprint*. <https://doi.org/10.48550/arXiv.2501.13400>
- Justam, Malik, A., Erlita, Mangellak, D., & Yuyun. (2024). Perbandingan Kinerja YOLO vs Faster R-CNN untuk Deteksi & Estimasi Berat Ikan. *Jurnal Ilmiah Sistem Informasi Dan Teknik Informatika (JISTI)*, 7(2), 363–376. <https://doi.org/10.57093/jisti.v7i2.273>
- Karyanto, D. D., Indra, J., Pratama, A. R., & Rohana, T. (2024). Detection of the Size of Plastic Mineral Water Bottle Waste Using the YOLOv5 Method. *JIKO (Jurnal Informatika Dan Komputer)*, 7(2), 123–130. <https://doi.org/10.33387/jiko.v7i2.8535>
- Kementerian Lingkungan Hidup dan Kehutanan (KLHK). (2024). *Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) Tahun 2024*. <https://sipsn.menlhk.go.id/sipsn/>
- Kunwar, S., Owabumoye, B. R., & Alade, A. S. (2025). Plastic Waste Detection Using Deep Learning: Insights from the WaDaBa Dataset. *Industrial and Domestic Waste Management*, 5(1), 1–11. <https://doi.org/10.53623/idwm.v5i1.580>
- Liu, G., Nouaze, J. C., Mbouembe, P. L. T., & Kim, J. H. (2020). YOLO-tomato: A Robust Algorithm for Tomato Detection Based on YOLOv3. *Sensors (Switzerland)*, 20(7), 1–20. <https://doi.org/10.3390/s20072145>
- Martinez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernandez-Orallo, J., Kull, M., Lachiche, N., Ramirez-Quintana, M. J., & Flach, P. (2021). CRISP-DM Twenty Years Later: From

- Data Mining Processes to Data Science Trajectories. *IEEE Transactions on Knowledge and Data Engineering*, 33(8), 3048–3061. <https://doi.org/10.1109/TKDE.2019.2962680>
- Rahman, M. W., Islam, R., Hasan, A., Bithi, N. I., Hasan, M. M., & Rahman, M. M. (2022). Intelligent Waste Management System using Deep Learning with IoT. *Journal of King Saud University - Computer and Information Sciences*, 34(5), 2072–2087. <https://doi.org/10.1016/j.jksuci.2020.08.016>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-time Object Detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Schröer, C., Kruse, F., & Gomez, J. M. (2021). A Systematic Literature Review on Applying Process Model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Vieri, D., Susanto, R., Purwanto, E. S., & Ario, M. K. (2024). Enhancing Waste Classification with YOLOv8 Models for Efficient and Accurate Sorting. *Procedia Computer Science*, 245, 889–895. <https://doi.org/10.1016/j.procs.2024.10.316>
- Visen, & Charibaldi, N. (2025). Penerapan Object Detection Menggunakan Deep Learning YOLOv8 untuk Mengidentifikasi Sampah Anorganik (Maksimal Sepuluh Objek) dalam Satu Citra. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 12(1), 195–202. <https://doi.org/10.25126/jtiik.2025129012>
- World Bank. (2018). *Trend in Solid Waste Management*. https://datatopics.worldbank.org/what-a-waste/trends_in_solid_waste_management.html
- Yasiri, J. R., Prathivi, R., & Susanto. (2025). Detection of Plastic Bottle Waste Using YOLO Version 5 Algorithm. *Sinkron: Jurnal Dan Penelitian Teknik Informatika*, 9(1), 20–30. <https://doi.org/10.33395/sinkron.v9i1.14242>