

## Evaluasi Kinerja YOLOv8 dan SSD dalam Deteksi Real-Time Sampah Botol Plastik Berbasis Deep Learning

Alven Safik Ritonga<sup>1</sup>, Nurwahyudi Widhiyanta<sup>2</sup>, Eka Alifia Kusnanti<sup>3</sup>

<sup>1,2,3</sup> Universitas Wijaya Putra

<sup>1</sup>alvensafik@uwp.ac.id, <sup>2</sup>nurwahyudiwidhiyanta@uwp.ac.id, <sup>3</sup>ekaalifia@uwp.ac.id

### ABSTRAK

Sampah botol plastik merupakan salah satu fraksi paling dominan dalam timbunan sampah kota dan berkontribusi besar terhadap pencemaran lingkungan. Laporan global memperkirakan jutaan ton plastik masuk ke ekosistem perairan setiap tahun dan jumlah ini terus meningkat. Deteksi otomatis botol plastik menggunakan deep learning berbasis deteksi objek satu-tahap (one-stage detector), menjadi pendekatan yang menjanjikan untuk mendukung aplikasi smart waste management seperti smart bin dan reverse vending machine. Penelitian ini mengevaluasi dan membandingkan kinerja YOLOv8 dan Single Shot MultiBox Detector (SSD) untuk deteksi real-time sampah botol plastik. Dataset yang digunakan merupakan gabungan 4.827 citra eksternal dan 251 citra internal, yang kemudian diaugmentasi menjadi lebih dari 10.000 sampel dan dianotasi untuk satu kelas bottle. Model YOLOv8 dilatih di Google Colab dengan GPU T4, sedangkan SSD diuji pada laptop berbasis CPU dalam dua skenario: (1) SSD-COCO menggunakan model pretrained umum, dan (2) SSD-Kustom yang di-fine-tune menggunakan dataset botol plastik. Hasil eksperimen menunjukkan bahwa YOLOv8 mencapai  $mAP@0,5 \approx 0,984$  untuk kelas botol dengan kurva precision - recall yang stabil. SSD-COCO menghasilkan sekitar 5 FPS di CPU, namun hanya mampu mendeteksi botol pada 4,07% dari 18.755 frame uji. Sebaliknya, SSD-Kustom mempertahankan FPS yang sebanding tetapi mendeteksi botol pada 100% dari 2.154 frame dengan rata-rata  $\approx 171$  deteksi per detik, yang mengindikasikan sensitivitas tinggi namun disertai gejala over-detection. Secara keseluruhan, YOLOv8 memberikan keseimbangan terbaik antara akurasi dan stabilitas, sedangkan SSD-Kustom berpotensi menjadi alternatif pada perangkat CPU-only setelah optimasi lanjutan terhadap confidence threshold dan non-maximum suppression.

**Kata Kunci**— Sampah botol plastik, deteksi objek, YOLOv8, SSD, deep learning, real-time.

### ABSTRACT

Plastic bottle waste is one of the most dominant fractions of municipal solid waste and contributes significantly to environmental pollution. Global reports estimate that millions of tons of plastic are discharged into aquatic ecosystems every year, with a steadily increasing trend. Automatic detection of plastic bottles using deep learning-based one-stage object detectors is a promising approach to support smart waste management applications such as smart bins and reverse vending machine. This study evaluates and compares the performance of YOLOv8 and Single Shot MultiBox Detector (SSD) for real-time plastic bottle detection. The dataset combines 4,827 external images and 251 internally acquired images, which are then augmented to more than 10,000 samples and annotated for a single bottle class. YOLOv8 is trained on Google Colab with a T4 GPU, while SSD is evaluated in two scenarios on a CPU laptop: (1) SSD-COCO using a generic pretrained model, and (2) SSD-Custom fine-tuned on the plastic bottle dataset. Experimental results show that YOLOv8 achieves  $mAP@0.5 \approx 0.984$  for the bottle class with high precision - recall stability. SSD-COCO reaches about 5 FPS on CPU but detects bottles in only 4.07% of 18,755 tested frames. In contrast, SSD-Custom maintains similar FPS, but detects bottles in 100% of 2,154 frames with an average of  $\approx 171$  detections per second, indicating strong sensitivity but also over-detection. Overall, YOLOv8 provides the best balance of accuracy and stability, whereas SSD-Custom becomes a viable alternative for CPU-only deployment after further optimization of confidence threshold and non-maximum suppression.

**Keywords**— Plastic bottle waste, object detection, YOLOv8, SSD, deep learning, real-time.

## I. PENDAHULUAN

Produksi plastik global terus meningkat dan diikuti oleh tingginya timbunan sampah plastik yang tidak tertangani dengan baik.[1] memperkirakan bahwa 275 juta ton sampah plastik dihasilkan di 192 negara pesisir pada tahun 2010, dengan 4,8–12,7 juta ton di antaranya masuk ke lautan. Laporan UNEP “From Pollution to Solution” menegaskan bahwa volume sampah plastik yang memasuki ekosistem perairan dapat meningkat hingga 23–37 juta ton per tahun pada 2040 jika tidak ada intervensi serius.[2] Botol plastik umumnya berbahan polyethylene terephthalate (PET), menjadi salah satu kontribusi utama karena tingkat daur ulang yang masih rendah dan sifatnya yang sulit terurai.

Salah satu tantangan utama dalam pengelolaan sampah botol plastik adalah proses identifikasi dan pemilahan yang masih didominasi cara manual, sehingga tidak efisien, memerlukan banyak tenaga, dan sulit diskalakan. Pendekatan berbasis visi komputer dan kecerdasan buatan membuka peluang untuk melakukan deteksi otomatis terhadap botol plastik dalam gambar maupun video secara real-time, misalnya pada smart bin dan reverse vending machine.

Di bidang deteksi objek, metode one-stage detector seperti YOLO (You Only Look Once) dan Single Shot MultiBox Detector (SSD) menjadi pilihan populer karena mampu melakukan inferensi cepat dengan arsitektur jaringan tunggal. YOLO diperkenalkan oleh sebagai pendekatan unified real-time object detection yang memetakan citra langsung menjadi bounding box dan class probabilities dalam satu forward pass.[3] Metode SSD menggunakan multi-scale feature maps dan sekumpulan default boxes untuk mendeteksi objek dengan berbagai ukuran. [4]

Berbagai penelitian telah menerapkan YOLO maupun CNN lain untuk deteksi dan klasifikasi sampah. Sari dan Jumadi, misalnya, mengembangkan sistem klasifikasi sampah organik dan non-organik berbasis CNN untuk membantu pemilahan otomatis.[5] Kirana menggunakan YOLOv6 dan YOLOv7 untuk mendeteksi sampah botol yang mengapung di permukaan air dan melaporkan nilai mAP hingga 0,873.[6] Yasiri dkk. menerapkan YOLOv5 untuk deteksi sampah botol plastik dan menunjukkan bahwa detektor tunggal tersebut efektif pada skenario gambar statis.[7] Selain itu, Kestane dkk. mengevaluasi YOLOv8 untuk deteksi real-time material daur ulang pada reverse vending machine dan mencapai akurasi di atas 97% untuk beberapa jenis material.[8]

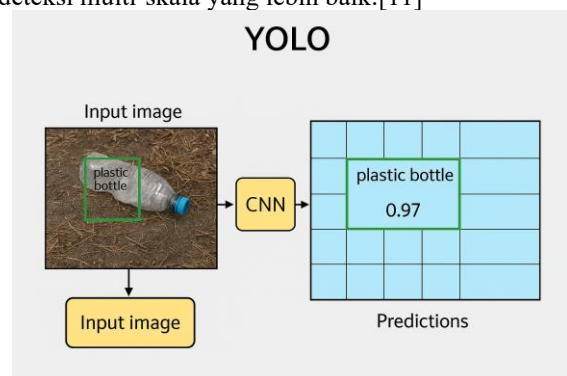
Sebagian besar studi tersebut berfokus pada satu keluarga metode (misalnya hanya YOLO) dan belum banyak yang membandingkan YOLOv8 dengan SSD dalam skenario yang benar-benar sama, khususnya untuk deteksi botol plastik secara real-time di perangkat dengan sumber daya terbatas. Di sisi lain, kajian tentang dampak fine-tuning SSD pada dataset spesifik botol plastik terhadap kinerja real-time di CPU juga masih terbatas.[9]

Penelitian ini bertujuan mengisi celah tersebut dengan melakukan evaluasi komparatif antara YOLOv8 dan SSD dalam tiga konfigurasi: YOLOv8 berbasis GPU, SSD-COCO (pretrained umum) di CPU, dan SSD-Kustom yang di-fine-tune pada dataset botol plastik dan diuji secara real-time di CPU. Rangkuman metodologi dan hasil awal penelitian ini telah dilaporkan dalam laporan kemajuan internal.

## II. TINJAUAN PUSTAKA

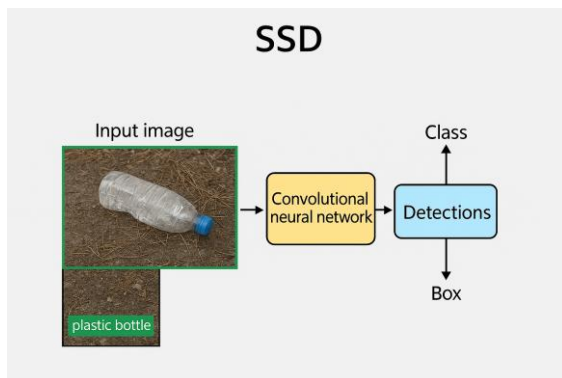
### A. Deteksi Objek Berbasis Deep Learning

YOLO memformulasikan deteksi objek sebagai masalah regresi yang secara langsung memprediksi koordinat bounding box dan probabilitas kelas dari citra penuh dalam satu jaringan saraf. Pendekatan ini menghasilkan kecepatan tinggi, hingga puluhan frames per second (FPS) pada GPU, menjadikannya cocok untuk aplikasi real-time.[10] Generasi terbaru seperti YOLOv8 memperkenalkan arsitektur anchor-free, kombinasi backbone CSPNet serta FPN+PAN untuk deteksi multi-skala yang lebih baik.[11]



Gambar 1. Ilustrasi Algoritma YOLO

SSD adalah single-shot detector yang menggunakan beberapa feature maps konvolusional dengan ukuran berbeda untuk memprediksi sekumpulan default boxes beserta skor kelasnya, tanpa tahap region proposal. Model ini dikenal memiliki kompromi yang baik antara mAP dan kecepatan, terutama ketika dipadukan dengan backbone ringan seperti MobileNet.[12]



Gambar 2. Ilustrasi Algoritma SSD

### B. Deteksi dan Klasifikasi Sampah

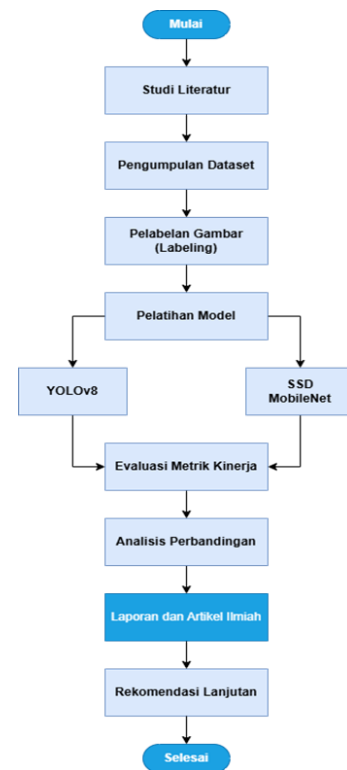
Penelitian terkait pengelolaan sampah berbasis visi komputer semakin berkembang. Pieters mengembangkan sistem klasifikasi citra sampah organik dan non-organik berbasis CNN dengan tujuan mendukung sistem pemilahan otomatis. [13]

Kirana dkk. menerapkan YOLOv6 dan YOLOv7 untuk deteksi sampah botol plastik pada permukaan air dan melaporkan bahwa YOLOv6 memberikan mAP lebih tinggi dan inferensi lebih cepat dibanding YOLOv7 pada dataset FloW-Img.[6] Ananta dkk. menunjukkan efektivitas YOLOv5 dalam mendeteksi sampah botol plastik pada citra statis dengan tingkat akurasi yang memadai untuk mendukung pengelolaan sampah perkotaan. [14]

Pada sisi lain, Triyanto dkk. memperlihatkan bahwa YOLOv8 dapat diintegrasikan ke reverse vending machine untuk deteksi material daur ulang secara real-time, dengan akurasi klasifikasi di atas 97% untuk beberapa jenis material.[15] Temuan-temuan ini menguatkan potensi metodologi YOLO dan SSD untuk diaplikasikan pada sistem pemilahan sampah cerdas.

## III. METODOLOGI

Penelitian ini menggunakan metode kuantitatif eksperimental dengan pendekatan komparatif. Penelitian ini dibagi menjadi beberapa tahapan utama, berikut adalah tahapan-tahapan tersebut, yang ditampilkan dalam bentuk bagan alir penelitian berikut ini;




Gambar 3. Diagram Alir Penelitian

### A. Dataset dan Anotasi

Dataset terdiri atas dua sumber utama:

1. Dataset eksternal dari Roboflow dan TrashNet, dengan total 4.827 gambar botol plastik dalam berbagai latar belakang dan kondisi pencahayaan, seperti contoh di gambar 4 [16][17].
2. Dataset internal sebanyak 251 gambar yang diambil menggunakan smartphone di lingkungan nyata seperti ruang kuliah, rumah, dan area publik, seperti contoh pada gambar 5.



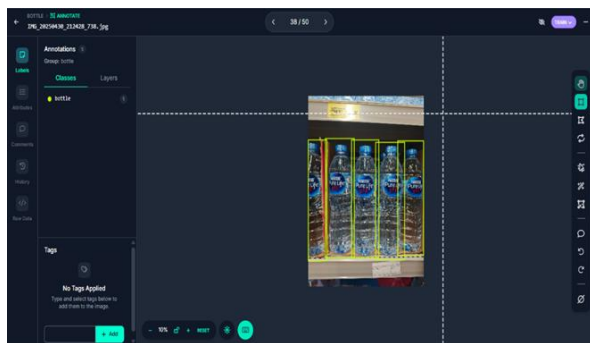
Gambar 4. Data Eksternal Botol Bekas



Gambar 5. Data Internal Botol Bekas

Seluruh gambar dianotasi menggunakan Roboflow dan labeling tool lain dengan satu kelas bottle, seperti gambar 6 dibawah ini. Anotasi diekspor dalam dua format:

- Berkas .txt dengan format YOLO untuk pelatihan YOLOv8.
- Berkas .xml (Pascal VOC) untuk pelatihan SSD.



Gambar 6. Proses Anotasi

Melalui proses preprocessing dan augmentation (resize ke 640×640, flip, rotasi, perubahan brightness, saturasi, blur, dan noise), ukuran dataset diperluas menjadi sekitar 10.050 citra yang kemudian dibagi menjadi subset pelatihan, validasi, dan pengujian.

### B. Pelatihan YOLOv8

Pelatihan YOLOv8 dilakukan di Google Colab dengan GPU Nvidia T4 menggunakan pustaka Ultralytics. Konfigurasi utama meliputi:

- Resolusi input: 640×640 piksel.
- Batch size: 8.
- Jumlah epoch: 50.
- Optimizer dan learning rate mengikuti pengaturan default Ultralytics.
- Augmentasi: otomatis dari YOLOv8 (mosaic, flip, perubahan skala dan warna).

Selama pelatihan, metrik yang dipantau meliputi box loss, cls loss, dfl loss, serta mAP@0.5 dan mAP@0.5:0.95 pada subset validasi.

### C. Arsitektur SSD dan Skenario SSD-COCO

Untuk SSD digunakan arsitektur SSDLite320 MobileNetV3-Large dari torchvision yang telah dilatih sebelumnya pada dataset COCO. Model ini dirancang untuk perangkat ringan dengan backbone MobileNetV3 yang efisien.

Skenario SSD-COCO menggunakan model pretrained tersebut tanpa fine-tuning, dengan kelas bottle diidentifikasi berdasarkan indeks kelas COCO. Deteksi real-time dijalankan di laptop CPU (Intel-based) dengan input video dari webcam 640×480. Ambang kepercayaan awal ditetapkan pada 0,35 dan non-maximum suppression (NMS) standar dari torchvision.

### D. Pelatihan SSD-Kustom

Untuk meningkatkan kemampuan SSD dalam mengenali botol plastik, dilakukan fine-tuning menggunakan dataset yang sama dengan YOLOv8, namun dalam format VOC/XML. Model awal SSDLite320 MobileNetV3-Large dimodifikasi pada bagian head klasifikasi agar hanya memprediksi satu kelas objek (bottle) selain background.

Pelatihan dilakukan di lingkungan Python pada laptop yang sama, dengan parameter umum:

- Optimizer: SGD dengan momentum.
- Learning rate awal: 1e-3 dengan step decay.
- Batch size: 8.
- Epoch: 50.

Model terbaik disimpan sebagai `ssd_plastic_bottle_best.pth` berdasarkan kehilangan validasi terendah.

### E. Pengujian Real-Time dan Analisis Log

Baik SSD-COCO maupun SSD-Kustom diuji dalam skenario real-time menggunakan skrip Python yang:

1. Membaca frame dari webcam.
2. Menjalankan inferensi SSD.
3. Menghitung jumlah bounding box dengan label bottle per frame.
4. Menghitung FPS menggunakan selisih waktu antar frame.
5. Menyimpan log ke CSV: timestamp, jumlah\_botol, fps.

Berkas log kemudian dianalisis menggunakan skrip analisis\_log.py berbasis Pandas untuk memperoleh:

- Statistik frame-level: jumlah baris, FPS rata-rata, minimum, maksimum, dan persentase frame yang mengandung ≥1 deteksi.
- Agregasi per detik: rata-rata FPS dan jumlah botol per detik.

### F. Metrik Evaluasi

Metrik utama yang digunakan adalah: precision, recall, F1-score, mAP@0.5, dan FPS, sebagaimana umum digunakan pada penelitian deteksi objek. Selain

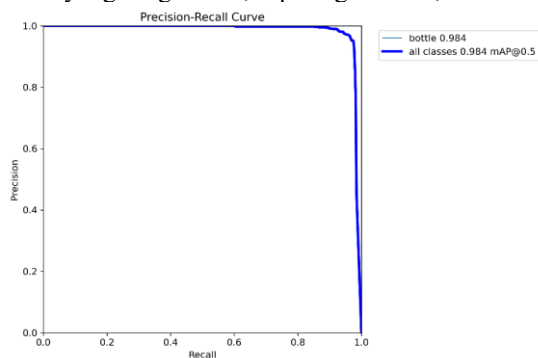


itu, untuk SSD-COCO dan SSD-Kustom dievaluasi pula jumlah deteksi per detik sebagai indikator sensitivitas (sekaligus potensi over-detection).

#### IV. HASIL DAN PEMBAHASAN


##### A. Kinerja YOLOv8

Pelatihan YOLOv8 menunjukkan konvergensi yang baik, dengan *box loss* dan *cls loss* yang menurun stabil hingga epoch ke-50. Kurva precision-recall untuk kelas *bottle* mendekati sudut kanan atas dengan nilai  $mAP@0.5 \approx 0,984$ , mengindikasikan kemampuan deteksi yang sangat baik, seperti gambar 7, berikut ini.




Gambar 7. Kurva Precision Recall


Kurva precision-confidence menunjukkan bahwa ketika *confidence threshold* dinaikkan hingga sekitar 0,93, nilai precision mendekati 1,0 (nyaris tanpa *false positive*), seperti gambar 8 di bawah ini. Sebaliknya, kurva recall-confidence memperlihatkan bahwa recall sedikit menurun ketika *threshold* dinaikkan, namun masih berada pada kisaran tinggi (sekitar 0,98 pada *threshold* rendah), seperti yang diperlihatkan pada gambar 9. *Confusion matrix* menegaskan dominasi *true positive* dibanding *false positive* dan *false negative*, sehingga YOLOv8 terbukti stabil dalam mengenali botol plastik pada berbagai variasi latar belakang dan pencahayaan, dapat dilihat seperti pada gambar 10.



Gambar 8. Kurva Precision Confidence




Gambar 9. Kurva Recall Confidence



Gambar 10. Confusion Matrix Metode YOLOv8

##### B. Kinerja Real-Time SSD-COCO

Analisis log SSD-COCO menghasilkan 18.755 baris data frame dengan FPS rata-rata 5,43, FPS minimum 1,49, dan maksimum 9,11. Dari seluruh frame tersebut, hanya 4,07% yang mengandung  $\geq 1$  deteksi botol, dengan rata-rata 0,07 deteksi botol per detik pada level agregasi detik, seperti gambar 11 berikut ini..



Gambar 11. Grafik FPS sistem deteksi sampah botol plastik berbasis SSD-COCO terhadap waktu


Secara visual, SSD-COCO mampu mendeteksi botol plastik ketika objek berada pada posisi ideal (dekat kamera dan kontras dengan latar belakang). Namun pada banyak kondisi, terutama ketika botol berada di tepi citra, tertutup sebagian, atau berada pada pencahayaan redup, detektor tidak memberikan *bounding box*. Hal ini dapat dijelaskan oleh fakta bahwa model COCO dilatih pada domain yang sangat umum dan tidak dioptimalkan khusus untuk variasi botol plastik yang digunakan dalam penelitian ini.

Dari sisi kecepatan, FPS sekitar 5–6 pada CPU sudah cukup untuk aplikasi monitoring sederhana, tetapi rendahnya persentase frame dengan deteksi botol menjadikan SSD-COCO kurang layak sebagai detektor utama untuk sistem pemilahan sampah.

### C. Kinerja Real-Time SSD-Kustom

Pada SSD-Kustom, pengujian real-time menghasilkan 2.154 frame dengan FPS rata-rata 5,19 (minimum 1,43, maksimum 8,83). Berbeda dengan SSD-COCO, seluruh frame (100%) tercatat mengandung  $\geq 1$  deteksi botol. Pada agregasi per detik, jumlah deteksi rata-rata mencapai 171,22 deteksi per detik, dengan FPS per detik sekitar 4,93, seperti yang diperlihatkan di gambar 12.

Nilai ini menandakan bahwa model sangat sensitif terhadap pola visual botol plastik—nyaris setiap frame mengandung banyak bounding box yang saling tumpang tindih di sekitar objek yang sama. Secara visual, hal ini terlihat sebagai fenomena over-detection, yaitu banyaknya kotak deteksi di area botol tunggal maupun area sekitarnya.



Gambar 12. Grafik FPS sistem deteksi sampah botol plastik berbasis SSD-Kustom terhadap waktu

Di satu sisi, sensitivitas tinggi ini menguntungkan untuk memastikan bahwa botol tidak terlewat. Di sisi lain, jumlah false positive berpotensi meningkat,

terutama jika sistem downstream (misalnya aktuatur pada vending machine) mengandalkan jumlah deteksi sebagai indikator tindakan. Fenomena ini kemungkinan dipengaruhi oleh kombinasi confidence threshold yang terlalu rendah, parameter NMS yang belum dioptimasi, serta proses pelatihan yang sangat fokus pada satu kelas sehingga model cenderung mengasosiasikan pola latar belakang tertentu sebagai botol.

### D. Perbandingan YOLOv8, SSD-COCO, dan SSD-Kustom

Aspek	YOLOv8 (GPU)	SSD-COCO (CPU)	SSD-Kustom (CPU)
Domain pelatihan	Dataset botol plastik khusus	COCO umum (80 kelas)	Dataset botol plastik khusus
mAP@0.5 kelas <i>bottle</i>	$\approx 0,984$	Tidak dihitung (hanya real-time)	$\approx 2,02\%$
Rata-rata FPS	$\sim 6-7$ (GPU T4, pelatihan/inferensi)	5,43 (laptop CPU, webcam)	5,19 (laptop CPU, webcam)
% frame dengan $\geq 1$ botol	Sangat tinggi (pada uji validasi gambar)	4,07% dari 18.755 frame	100% dari 2.154 frame
Deteksi botol per detik	Tidak dievaluasi sebagai deret waktu	$0,07 \text{ detik}^{-1}$	$171,22 \text{ detik}^{-1}$
Karakter dominan	Akurasi tinggi, prediksi stabil	Sensitivitas rendah, banyak objek terlewat ( <i>under-detect</i> )	Sensitivitas sangat tinggi, <i>over-detection</i>
Kebutuhan perangkat keras	GPU/NPU untuk performa optimal	Hanya CPU; ringan	Hanya CPU; lebih berat dari COCO tetapi masih real-time

Tabel 1. Ringkasan Perbandingan YOLOv8, SSD-COCO, dan SSD-Kustom

Tabel 1 di atas merangkum perbandingan tiga konfigurasi model berdasarkan hasil eksperimen. Dilihat dari tabel tersebut, YOLOv8 memberikan akurasi dan stabilitas deteksi terbaik dan cocok sebagai benchmark utama, sejalan dengan laporan lain yang menunjukkan superioritas varian YOLO baru untuk deteksi real-time pada berbagai domain. Namun model ini membutuhkan GPU atau NPU agar kecepatan inferensi terjaga pada sistem produksi.

SSD-COCO relatif ringan dan mudah diintegrasikan di CPU, tetapi kinerjanya kurang memadai untuk konteks deteksi botol plastik karena pelatihan awalnya tidak spesifik. Hal ini konsisten dengan temuan bahwa model generik sering kali perlu

fine-tuning pada dataset domain-spesifik untuk mencapai performa optimal.

SSD-Kustom menunjukkan bahwa fine-tuning memang secara dramatis meningkatkan sensitivitas deteksi terhadap objek botol plastik. Namun tanpa pengaturan threshold dan NMS yang tepat, model cenderung menghasilkan terlalu banyak kotak deteksi. Dari perspektif sistem, fenomena ini masih dapat dimitigasi melalui post-processing tambahan (misalnya penggabungan kotak, tracking antar frame, atau pembatasan jumlah deteksi maksimum per area).

### KESIMPULAN

Penelitian ini mengevaluasi kinerja YOLOv8 dan SSD dalam deteksi real-time sampah botol plastik berbasis deep learning dengan tiga konfigurasi: YOLOv8 berbasis GPU, SSD-COCO, dan SSD-Kustom berbasis CPU. Dataset gabungan dari sumber eksternal dan internal dengan anotasi tunggal kelas bottle digunakan sebagai dasar pelatihan dan pengujian.

Berdasarkan hasil eksperimen dapat disimpulkan bahwa:

1. Model YOLOv8 yang dilatih pada dataset khusus botol plastik menunjukkan performa deteksi terbaik dengan mAP@0,5 dan mAP@0,5–0,95 masing-masing sebesar 1,00 (100%), presisi sekitar 95,4%, dan recall 97,6% pada data validasi. Hal ini menegaskan bahwa YOLOv8 mampu mendeteksi hampir seluruh objek botol dengan posisi *bounding box* yang sangat akurat dan jumlah *false positive* yang relatif kecil.
2. SSD-COCO yang menggunakan model SSDLite320 MobileNetV3 pretrained COCO gagal mendeteksi botol plastik pada confidence threshold 0,5; tidak ada satupun prediksi untuk kelas bottle sehingga mAP@0,5, presisi, dan recall praktis bernilai nol. Hasil ini menunjukkan bahwa model deteksi generik tidak dapat langsung digunakan pada domain sampah botol plastik tanpa fine-tuning khusus.
3. SSD-Kustom yang di-fine-tune menggunakan dataset botol plastik memperlihatkan recall yang cukup tinggi sebesar 71,6%, tetapi presisi hanya 0,52% dan mAP@0,5 sekitar 2,02%. Kombinasi TP yang cukup banyak dengan FP yang sangat besar mengindikasikan fenomena over-detection, selaras dengan observasi visual berupa banyaknya bounding box tumpang tindih di sekitar satu botol.
4. Dilihat dari kompromi antara akurasi dan kebutuhan komputasi, YOLOv8 menjadi pilihan utama ketika tersedia GPU/NPU, sedangkan SSD-Kustom berpotensi

diaplikasikan pada perangkat CPU-only setelah dilakukan optimasi lanjutan terhadap *confidence threshold*, konfigurasi *non-maximum suppression*, dan skema pelatihan agar presisi meningkat tanpa menurunkan *recall* secara drastis.

### UCAPAN TERIMA KASIH

Penelitian ini tidak akan dapat terlaksana tanpa dukungan dan bantuan dari berbagai pihak. Oleh karena itu, kami ingin mengucapkan terima kasih yang sebesar-besarnya kepada; teman-teman peneliti dan rekan-rekan sesama dosen, mahasiswa-mahasiswa saya yang membantu dalam pengumpulan data.

### REFERENSI

- [1] J. R. Jambeck *et al.*, “Plastic waste inputs from land into the ocean,” *Science* (80-. ), vol. 347, no. 6223, pp. 764–768, 2015, doi: DOI: 10.1126/science.1260352.
- [2] UNEP (United Nations Environment Programme), *From pollution to solution: a global assessment of marine litter and plastic pollution*, vol. 237, no. 3169. 2021. [Online]. Available: <https://www.unep.org/resources/pollution-solution-global-assessment-marine-litter-and-plastic-pollution>
- [3] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 779–788, 2016, doi: 10.1109/CVPR.2016.91.
- [4] W. L. B *et al.*, “SSD : Single Shot MultiBox Detector,” *Springer Int. Publ.*, vol. 1, pp. 21–37, 2016, doi: 10.1007/978-3-319-46448-0.
- [5] A. T. Sari and E. Nurlatifah, “Penerapan Convolutional Neural Network untuk Mengklasifikasikan Citra Sampah Organik dan Non Organik,” *J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 14, no. 1, pp. 1–11, 2025.
- [6] N. L. Kirana, D. Kurnianingtyas, and Indriati, “A Deep Learning Approach to Plastic Bottle Waste Detection on the Water Surface using YOLOv6 and YOLOv7,” *Eng. Technol. Appl. Sci. Res.*, vol. 14, no. 6, pp. 18623–18630, 2024, doi: 10.48084/etasr.8592.
- [7] J. R. Yasiri, R. Prathivi, and S. Susanto, “Detection of Plastic Bottle Waste Using YOLO Version 5 Algorithm,” *Sinkron*, vol. 9, no. 1, pp. 20–30, 2025, doi: 10.33395/sinkron.v9i1.14242.
- [8] B. B. Kestane, E. Guney, and C. Bayilmis,

- “Real-time Recyclable Waste Detection Using YOLOv8 for Reverse Vending Machines,” *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 10, no. 2, pp. 345–358, 2024, doi: 10.26555/jiteki.v10i2.29208.
- [9] Y. Ren, Y. Li, and X. Gao, “An MRS-YOLO Model for High-Precision Waste Detection and Classification,” *Sensors*, vol. 24, no. 13, pp. 1–22, 2024.
- [10] D. N. Alfarizi, R. A. Pangestu, D. Aditya, M. A. Setiawan, and P. Rosyani, “Penggunaan Metode YOLO Pada Deteksi Objek: Sebuah Tinjauan Literatur Sistematis,” *J. Artif. Intel. dan Sist. Penunjang Keputusan*, vol. 1, no. 1, pp. 54–63, 2023, [Online]. Available: <https://jurnalmahasiswa.com/index.php/aidanspk>
- [11] F. Feng, Y. Hu, W. Li, and F. Yang, “Improved YOLOv8 algorithms for small object detection in aerial imagery,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 36, no. 6, pp. 1–18, 2024, doi: 10.1016/j.jksuci.2024.102113.
- [12] S. N. Azzahra and D. Widhiantoro, “Analisa Komparatif Algoritma YOLO dan SSD untuk Sistem Deteksi Objek,” *Sniv:Seminar Nasional Inovasi dan Sivikasi*, vol. 4, no. 1, pp. 759–767, 2025.
- [13] L. Stephen Pieters, “Development of Automatic Waste Classification System Using Cnn Based Deep Learning To Support Smart Waste Management Pengembangan Sistem Klasifikasi Sampah Otomatis Menggunakan Deep Learning Berbasis Cnn Untuk Mendukung Smart Waste Management,” *J. Inovtek Polbeng*, vol. 10, no. 1, p. 1, 2025, doi: <https://doi.org/10.35314/wst8mh87>.
- [14] F. Ananta;, M. Kallista, and C. Setianingsih, “Deteksi Sampah Plastik Menggunakan Algoritma Yolov5 (You Only Look Once Version 5),” *e-Proceeding Eng.*, vol. 11, no. 3, pp. 1695–1701, 2024.
- [15] D. Triyanto, M. Zidan, M. Wahyudi, and L. Pujiastuti, “Pengembangan Sistem Deteksi Objek Botol Real-Time dengan YOLOv8 untuk Aplikasi Vision,” *Indones. J. Comput. Sci.*, vol. 3, no. 1, pp. 44–50, 2024, doi: <https://doi.org/10.31294/ijcs.v3i1.6070>.
- [16] Neld, “Bottle Computer Vision Model [Data set],” Roboflow Universe. [Online]. Available: <https://universe.roboflow.com/neld/bottle-0exyr-wwwxfz>
- [17] M. Yang and G. Thung, “Trashnet dataset,” *Kaggle*, 2017, [Online]. Available: <https://www.kaggle.com/datasets/feyzazkefe/tr>

ashnet