

Deteksi Objek Sampah Organik dan Anorganik Menggunakan YOLOv9

^{1*}**Rio Agung Dewangga, ²Resty Wulanningrum, ³Umi Mahdiyah**

^{1, 2, 3}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: ¹rioagung8536@gmail.com, ²restyw@unpkdr.ac.id, ³umimahdiyah@unpkediri.ac.id

Penulis Korespondens : Rio Agung Dewangga

Abstrak— Sampah merupakan sisa kegiatan sehari-hari manusia atau proses alam yang berbentuk padat. Secara umum, sampah dikelompokkan menjadi dua yakni sampah organik dan anorganik. Tujuan dari penelitian ini adalah untuk mengatasi permasalahan serius terkait sampah organik dan anorganik yang berdampak besar terhadap lingkungan. Pada penelitian ini digunakan model deteksi YOLOv9 untuk mengenali jenis sampah organik dan anorganik supaya sampah dapat dipilah dan dimanfaatkan sesuai jenisnya dengan baik. Dilakukan pembagian dengan presentase 70% untuk data pelatihan (*training*), 20% untuk validasi, dan 10% untuk pengujian (*testing*) terhadap 392 gambar dengan *epoch* sebanyak 100 kali. Penelitian menghasilkan performa yang baik yang dimana nilai rata-rata precision sebesar 0,937, recall 0,924, serta mAP50 dan mAP50-95 sebesar 0,857 dan 0,888. Pada objek dengan kelas *anorganik_paper* dan *anorganik_metal* memperoleh performa terbaik dan pada kelas *organic_leaf* dan *organic_food_waste* mendapatkan akurasi relatif rendah. Ini menunjukkan bahwa model YOLOv9 menunjukkan kinerja yang sangat baik dalam mengklasifikasikan jenis sampah.

Kata Kunci— Deteksi Objek, YOLOv9, Sampah

Abstract— Waste is the solid residue of human daily activities or natural processes. In general, waste is classified into two types: organic and inorganic. The purpose of this study is to address serious issues related to organic and inorganic waste that have a significant impact on the environment. In this study, the YOLOv9 detection model was used to identify the types of organic and inorganic waste so that the waste can be sorted and utilized appropriately according to its type. The data was divided into 70% for training, 20% for validation, and 10% for testing, using 392 images with 100 epochs. The study yielded good performance, with an average precision of 0.937, recall of 0.924, and mAP50 and mAP50-95 of 0.857 and 0.888, respectively. Objects in the *anorganic_paper* and *anorganic_metal* classes achieved the best performance, while the *organic_leaf* and *organic_food_waste* classes had relatively low accuracy. This indicates that the YOLOv9 model demonstrates excellent performance in classifying waste types.

Keywords— Object Detection, YOLOv9, Trash

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Sampah merupakan penyebab utama tercemarnya lingkungan. Setiap harinya, masyarakat menghasilkan sampah dalam bentuk padat dengan volume 3-1 kg [1]. Sampah merupakan sisa kegiatan sehari-hari manusia atau proses alam yang berbentuk padat [2]. Berdasarkan Kamus Besar Bahasa Indonesia, sampah adalah benda atau barang yang dibuang karena sudah tidak digunakan kembali seperti daun, kertas, dan lain sebagainya [3].

Permasalahan mengenai sampah merupakan hal yang sangat umum ditemui, saat ini Indonesia menempati peringkat sebagai negara penyumbang sampah plastik ke lautan terbesar kedua di dunia berdasarkan data dari Asosiasi Industri Plastik Indonesia (INAPLAS) dan Badan Pusat Statistik (BPS) yang menyatakan bahwa Indonesia dapat memproduksi sampah plastik hingga 64 juta ton per tahunnya dan sebanyak 3,2 juta ton sampah plastik yang berakhir ke lautan dan sekitar 85.000 ton sampah plastik yang terbuang di daratan [4]. Secara umum, sampah dikelompokkan menjadi dua yakni sampah organik dan anorganik.

Sampah organik merupakan jenis sampah yang paling banyak dihasilkan oleh masyarakat, sampah ini memiliki kandungan air yang tinggi sehingga mengalami pembusukan yang cepat dan saat membusuk, sampah jenis ini menimbulkan bau busuk yang dapat menyebabkan pencemaran lingkungan serta berpotensi menjadi sarang penyakit [5]. Sampah organik berasal dari bahan hayati yang dapat diuraikan oleh mikroorgansime, seperti sisa makanan, sayuran, daun dan buah-buahan [6]. Sedangkan sampah anorganik tidak berasal dari makhluk hidup (non hayati) melainkan berasal dari bahan yang bisa diperbaharui dan bahan yang berbahaya serta beracun, contoh sampah yang dapat didaur ulang misalnya bahan yang terbuat dari plastik dan logam [7]. Permasalahan mengenai sampah organik maupun anorganik menjadi sangat serius mengingat dampaknya yang luar biasa pada lingkungan, untuk menindaklanjuti permasalahan tersebut diperlukan sebuah teknologi untuk membantu memilah sampah berdasarkan jenisnya supaya sampah dapat segera ditangani dan tidak menyebabkan masalah pada jangka waktu yang panjang. Salah satu cabang ilmu komputer yang berfokus pada pengembangan sistem dimana komputer dapat melihat, mengenali, dan memahami gambar dan video secara otomatis serta memungkinkan komputer atau mesin melihat visual dunia nyata seperti layaknya manusia atau yang biasa disebut dengan computer vision [8] akan digunakan untuk memilah sampah organik dan anorganik pada penelitian ini.

Pada penelitian ini digunakan model deteksi YOLO-v9 untuk mengenali jenis sampah organik dan anorganik supaya sampah dapat dipilah dan dimanfaatkan sesuai jenisnya dengan baik. Seperti pada penelitian sebelumnya oleh Shenlin Liu (2024) yang dimana mengembangkan EcoDetect-YOLO, algoritma deteksi sampah berbasis *framework* YOLOv5s dan mendapatkan peningkatan 4,7% dalam mAP0.5 mencapai 58,1%. Penelitian tersebut dapat mempertahankan mAP0.5 diatas 50% yang menunjukkan ketahannya [9]. Berikutnya penelitian yang dilakukan oleh Saurav Kumar (2021) telah melakukan penelitian terhadap klasifikasi sampah berbasis YOLOv3 yang dimana terdapat enam objek yaitu (karton, kaca, logam, kertas, plastik, dan sampah organik) dan diperoleh hasil mAP sebesar 94,99%. Penelitian tersebut menunjukkan bahwa YOLOv3 dapat menghasilkan hasil baik dalam mendeteksi enam objek tersebut [10]. Demikian pula dengan penelitian yang dilakukan oleh QiuHong Sun (2023), menggunakan model deteksi sampah YOLOv5-OCDS berdasarkan YOLOv5 yang ditingkatkan. Hasil yang didapatkan meningkat untuk mAP50 sebesar 5,3% dan untuk mAP50-95 sebesar 12,3% dari perbandingan model YOLOv5s dan YOLOv5-OCDS [11].

Pada penelitian ini akan digunakan model YOLOv9 sebagai bentuk eksperimen atau uji coba yang dimana pada penelitian-penelitian sebelumnya, algoritma YOLO mendapatkan performa yang baik dalam mendeteksi dan mengidentifikasi jenis sampah.

II. METODE

2.1 Pengambilan Data

Data yang digunakan dalam penelitian ini diperoleh melalui dua metode utama yaitu pengumpulan dataset secara langsung di lapangan dan pemanfaatan dataset sekunder dari berbagai sumber internet. Untuk pengambilan data secara langsung dilakukan pengambilan video berbagai jenis sampah organik seperti sisa makanan, daun, ranting, dan kulit buah serta untuk sampah anorganik seperti plastik, kertas, karet, dan besi. Video tersebut diambil menggunakan kamera perangkat telepon dengan resolusi tinggi serta berdurasi sekitar satu menit pada semua jenis sampah.

2.2 Penyiapan Data

Proses penyiapan data dilakukan menggunakan *platform* roboflow yang dimana video tersebut dilakukan ekstrak gambar sebanyak 1 *frame* per detik dan diperoleh total 392 gambar. Tahapan-tahapan yang dilakukan selanjutnya yaitu

a) Anotasi

Setiap gambar hasil ekstraksi akan dilakukan proses anotasi yang dimana memberikan tanda pada objek sesuai dengan bentuknya menggunakan *polygon tool* agar sistem dapat dengan mudah mengenali objek tersebut. Pemberian label yang akan dilakukan untuk sampah organik yaitu *organic_leaf*, *organic_branch*, *organic_fruit_peel*, dan *organic_food_waste* lalu untuk sampah anorganik yaitu *anorganic_metal*, *anorganic_paper*, *anorganic_plastic*, dan *anorganic_rubber*.



Gambar 1 Anotasi Sampah Organik

Pada gambar tersebut dilakukan proses pelabelan pada objek kulit pisang sebagai salah satu jenis sampah organik dengan label *organic_fruit_peel*.

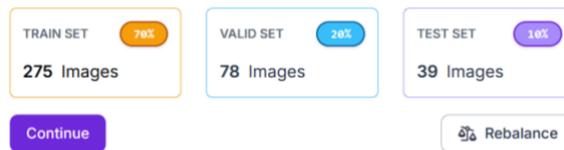


Gambar 2 Anotasi Sampah Anorganik

Pada gambar ini dilakukan proses anotasi terhadap objek berupa kaleng yang termasuk kedalam kategori sampah anorganik dengan label *anorganic_metal*.

b) Split Data

Selanjutnya data tersebut akan dilakukan pembagian dataset (*data splitting*) yang akan dibagi menjadi tiga bagian yaitu *train set*, *validation set*, dan *test set*. Proses pembagian data ini mengikuti metode yang digunakan dalam penelitian [16], yaitu dengan presentase pembagian 70% untuk data pelatihan (*training*), 20% untuk validasi, dan 10% untuk pengujian (*testing*).



Gambar 3 Split Data

Pembagian ini bertujuan untuk memastikan model dapat belajar secara baik dari data training, sambil tetap mampu menghindari overfitting melalui evaluasi kerja pada data validasi.

c) Preprocessing

Tahap selanjutnya yang akan dilakukan yaitu *preprocessing* sebagai langkah awal sebelum proses pemodelan. Pada tahap ini seluruh dataset dievaluasi kembali untuk memastikan bahwa data yang digunakan dalam pelatihan model bersih, konsisten, dan layak pakai. Pada proses *preprocessing* akan dilakukan *auto-orient* untuk memastikan sistem tetap dapat mengenali objek meskipun posisinya tidak dalam keadaan tegak lurus. Kemudian dilakukan *resize fit within* 640x640 agar semua gambar memiliki ukuran yang seragam yaitu 640x640 piksel.



Gambar 4 Preprocessing Resize Fit Within

Gambar tersebut memperlihatkan hasil proses *resize* dengan dimensi 640x640 piksel. Ukuran gambar tersebut disesuaikan agar bentuk objek dengan model tidak berubah.

d) Augmentasi

Untuk meningkatkan variasi data, dilakukan augmentasi berupa *flip vertical* dan *horizontal* agar model dapat mengenali objek dalam posisi terbalik atau cermin, *rotation between -15°* dan *+15 °* untuk menangani variasi sudut objek, serta *brightness between -25%* dan *+25%* untuk menyesuaikan tingkat pencahayaan pada objek.

2.3 Pemodelan

a. System Development Life Cycle (SDLC)

Model *waterfall* merupakan metode yang akan digunakan pada penelitian ini. Model *waterfall* atau model regular atau siklus hidup klasik pada model SDLC menggunakan pendekatan sistematis dan berurutan, mulai dari tingkat kebutuhan sistem dan berlanjut ke analisis, desain, pengkodean, dan pengujian/validasi[12].



Gambar 5. Model Waterfall

Dipilih model waterfall karena kelebihannya yang sederhana dan mudah dimengerti sebab setiap tahapannya didefinisikan dengan jelas, terstruktur, memiliki dokumentasi yang lengkap sehingga memudahkan dalam proses pemeliharaan, serta sesuai untuk digunakan pada proyek yang kecil [13].

b. YOLOv9

YOLOv9 (You Only Look Once Version 9) merupakan pengembangan dari arsitektur YOLO yang diperkenalkan oleh Chien-Yao Wang, I-Hau Yeh, dan Hong-Yuan Mark Liao pada awal tahun 2024[1]. Penelitian ini dirancang untuk mengembangkan sistem deteksi objek yang mampu mengidentifikasi jenis sampah, yaitu sampah organik dan anorganik dengan memanfaatkan model YOLOv9 yang merupakan pengembangan dari algoritma YOLO. Penelitian ini berfokus pada peningkatan akurasi dalam mendekripsi sampah organik karena dalam beberapa studi sebelumnya, jenis sampah ini sering kali menjadi tantangan dalam proses klasifikasi akibat bentuk, tekstur, dan warna yang sangat bervariasi.

2.4 Evaluasi

a) Precision

Precision adalah kemampuan model untuk mengidentifikasi hanya objek yang relevan, ini merupakan persentase prediksi positif (*True Positive*) [14]. Metrik ini memiliki rumus sebagai berikut

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

b) Recall

Recall adalah kemampuan model untuk menemukan semua kasus yang relevan (semua *ground-truth bounding boxes*) yang merupakan persentase prediksi positif yang benar diantara semua *ground truth* yang diberikan [15]. Pada matrik *recall* memiliki rumus seperti

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

c) Mean Average Precision (mAP)

Mean Average Precision (mAP) adalah metrik kinerja yang digunakan untuk mengevaluasi model pembelajaran mesin. mAP digunakan secara luas dalam evaluasi sistem deteksi objek karena menggabungkan *precision* dan *recall* dalam satu nilai.

- mAP50 adalah nilai rata-rata *precision* ketika *Intersection over Union* (IoU) $\geq 0,5$ dan memiliki rumus

$$mAP50 = \frac{1}{N} \sum_{i=1}^N AP_i^{0,5} \quad (3)$$

- mAP50-95 adalah nilai mAP rata-rata yang dihitung dari IoU 0,5 hingga 0,95 dengan interval 0,05 dengan rumus

$$mAP50:95 = \frac{1}{10 \times N} \sum_{t=0,5}^{0,95} \sum_{i=1}^N AP_i^t \quad (4)$$

Matriks-matriks evaluasi tersebut digunakan untuk mengamati hasil prediksi model serta menilai performa keseluruhan dari model YOLOv9 dalam mendekripsi dan mengklasifikasikan objek sampah.

III. HASIL DAN PEMBAHASAN

3.1 Hasil Deteksi Objek

Setelah melalui tahap preprocessing dan augmentasi, jumlah dataset meningkat menjadi 942 gambar. Akibat penambahan data ini, pembagian dataset yang sebelumnya menggunakan persentase 70%, 20%, dan 10% berubah menjadi 88% untuk train set, 8% untuk validation set, dan 4% untuk test set. Selanjutnya dilakukan tahap pemodelan menggunakan algoritma YOLO dengan model YOLOv9-e yang dilatih dengan dataset yang telah diproses sebelumnya. Model YOLOv9-e dipilih karena menurut dokumentasi resmi dari ultralytics varian ini menunjukkan performa yang paling optimal dibandingkan dengan varian lain pada model YOLOv9. Model ini mampu memberikan keseimbangan terbaik antara kecepatan dan tingkat akurasi dalam mendeteksi objek. Proses pelatihan (*training*) dilakukan sebanyak 100 *epoch*, berdasarkan pada penelitian [17], yang menunjukkan hasil yang memuaskan dengan jumlah epoch tersebut.

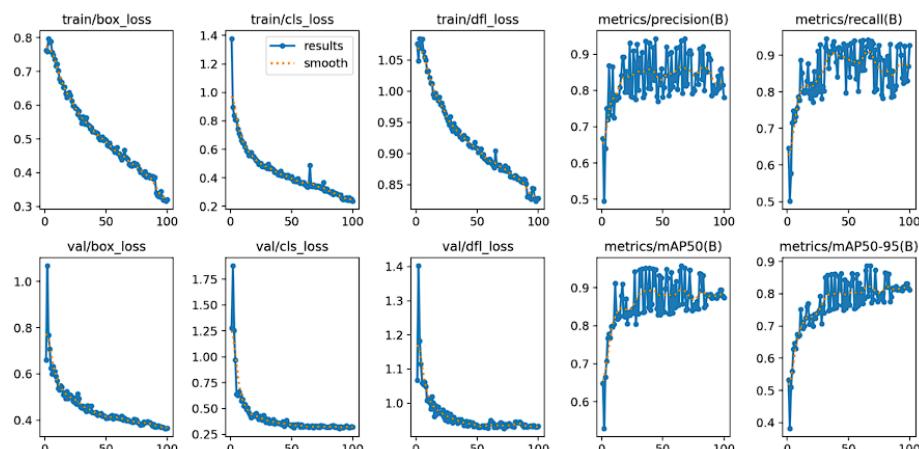
Tabel 1 Hasil Deteksi

Class	Images	Instances	P	R	mAP50	mAP50-95
<i>all</i>	78	764	0.937	0.924	0.958	0.887
<i>anorganik_metal</i>	7	54	1	0.929	0.994	0.935
<i>anorganik_paper</i>	21	28	0.996	1	0.995	0.984
<i>anorganik_plastic</i>	29	61	0.949	0.984	0.988	0.958
<i>anorganik_rubber</i>	4	38	0.938	0.842	0.915	0.803
<i>organik_branch</i>	3	3	0.902	1	0.995	0.962
<i>organik_food_waste</i>	2	23	0.849	0.826	0.852	0.757
<i>organik_fruit_peel</i>	23	190	0.952	0.95	0.984	0.919
<i>organik_leaf</i>	12	367	0.913	0.86	0.939	0.781

Hasil diatas menunjukkan hasil evaluasi performa model YOLOv9-e dalam mendeteksi delapan kelas sampah organik dan anorganik. Model menunjukkan kinerja yang sangat baik dengan nilai rata-rata mAP50 sebesar 0.957 dan mAP50-95 sebesar 0.888. Beberapa kelas seperti *anorganic_metal*, *anorganic_paper*, dan *anorganic_plastic* menunjukkan performa deteksi yang sangat tinggi dengan nilai *precision*, *recall*, dan mAP yang mendekati sempurna (1.0). Performa terendah ditunjukkan oleh kelas *organic_food_waste* dan *organic_leaf* yang memiliki nilai mAP50-95 paling rendah dibandingkan kelas lainnya.

3.2 Evaluasi

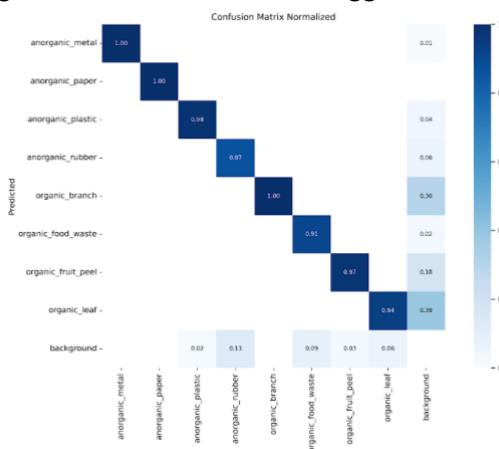
Hasil pengujian model YOLOv9-e ditampilkan melalui beberapa grafik dan *matrix* yang memberikan gambaran menyeluruh tentang performa sistem dalam mendeteksi sampah organik maupun anorganik.



Gambar 6 Grafik Hasil

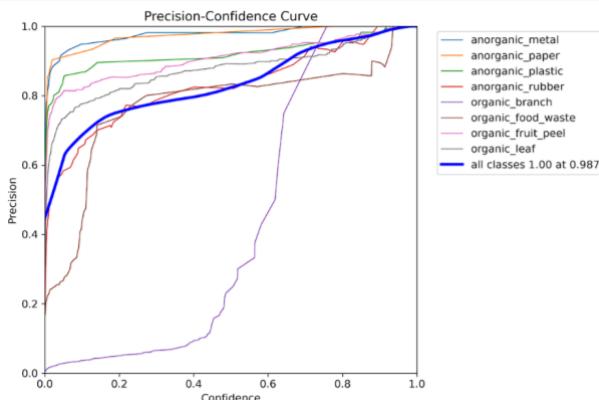
Gambar diatas menampilkan grafik evaluasi pelatihan model YOLOv9-e selama 100 epoch yang mencakup matrix utama seperti loss, precision, recall, dan mean Average Precision (mAP). Pada grafik diatas menunjukkan hasil sebagai berikut.

- Pada grafik train/box_loss, train/cls_loss, train/dfl_loss ini menunjukkan penurunan loss selama pelatihan. Ketiga loss menurun secara konsisten menunjukkan bahwa model berhasil belajar mengenali objek dengan lebih baik seiring bertambahnya epoch.
- Pada val/box_loss, val/cls_loss, val_dfl_loss ini juga menunjukkan penurunan loss secara bertahap. Ini membuktikan bahwa model tidak mengalami overfitting dan tetap mampu mempertahankan kinerja yang baik terhadap data baru yang belum digunakan saat pelatihan.
- Pada grafik metrics/precision(B) dan metrics/recall(B) menunjukkan bahwa precision dan recall mendapatkan stabilitas yang baik diatas angka 0.85-0.9 setelah sekitar 30 epoch. Ini menandakan bahwa model mampu mendeteksi objek dengan akurasi tinggi (precision) dan konsistensi dalam menemukan objek yang benar (recall).
- Pada grafik metrics/mAP50(B) dan mAP50-95(B) menampilkan performa model dalam mendeteksi objek dengan tingkat akurasi tinggi pada batas minimum IoU sebesar 0.5 yang berarti prediksi dianggap benar jika tumpang tinding dengan objek asli setidaknya 50% pada mAP50 sedangkan pada mAP50-95 menampilkan nilai rata-rata dari mAP yang dihitung pada berbagai ambang batas IoU mulai dari 0.5 hingga 0.95 dengan interval 0.05.



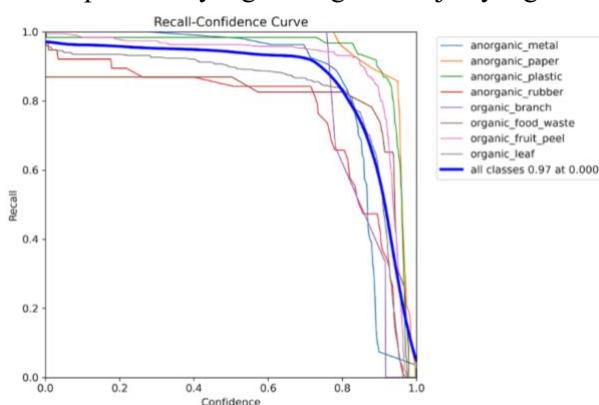
Gambar 7 Confusion Matrix Normalized

Berdasarkan *confusion matrix* yang telah dinormalisasikan tersebut menunjukkan bahwa model mendapatkan performa yang sangat baik pada beberapa kelas seperti *anorganic_metal*, *anorganic_paper*, dan *organic_branch* dengan akurasi 100%. Namun masih terdapat beberapa kebingungan yang cukup tinggi antara kelas *background* dan beberapa kelas *organic* terutama *organic_leaf* dengan 39% *background* diklasifikasikan salah sebagai daun yang menandakan model belum sepenuhnya mampu membedakan tampilan yang mirip antara objek dan latar belakang.



Gambar 8 *Precision Confidence Curve*

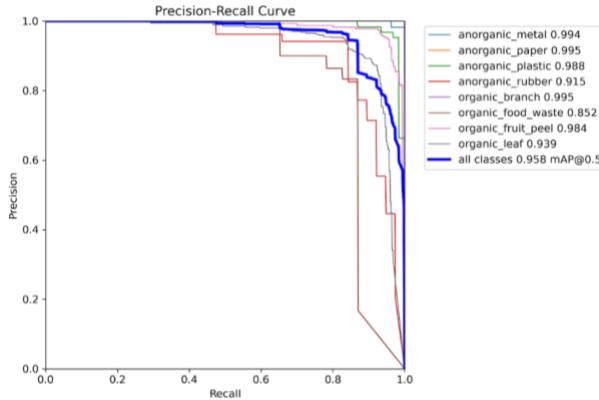
Grafik *precision-confidence curve* menunjukkan hubungan antara nilai *confidence* dan tingkat presisi model dalam mendekripsi objek untuk masing-masing kelas. Secara keseluruhan model mencapai presisi gabungan sebesar 1.00 pada *confidence* 0.987 yang menandakan bahwa hampir semua prediksi dengan tingkat keyakinan tinggi adalah benar. Semakin tinggi nilai *confidence* semakin tinggi pula presisi yang menunjukkan bahwa prediksi dengan *confidence* tinggi lebih dapat dipercaya. Kelas seperti *anorganic_metal*, *anorganic_paper*, dan *anorganic_plastic* memperlihatkan performa yang sangat baik dengan kurva presisi yang konsisten tinggi di sepanjang rentang *confidence*. Sementara itu kelas *organic_branch* dan *organic_food_waste* menunjukkan presisi rendah pada *confidence* rendah dan meningkat secara bertahap yang bisa disebabkan oleh jumlah data pelatihan yang kurang atau objek yang bervariasi.



Gambar 9 *Recall Confidence Curve*

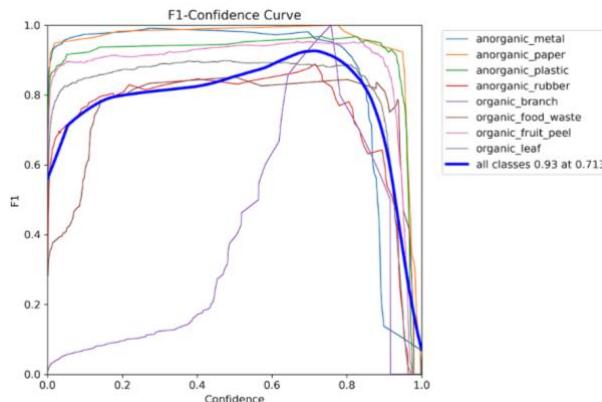
Grafik *recall-confidence curve* menunjukkan bahwa mode memiliki kemampuan deteksi sangat baik secara keseluruhan dengan recall gabungan untuk seluruh kelas mencapai 0.97 pada *confidence* rendah. Hal ini menunjukkan bahwa hampir seluruh objek berhasil dikenali ketika tidak ada batasan pada tingkat keyakinan model. Seiring meningkatnya nilai *confidence*, *recall*

cenderung menurun karena hanya prediksi dengan performa tinggi yang dipertahankan. Beberapa kelas seperti *anorganic_rubber* dan *organic_leaf* menunjukkan penurunan *recall* yang lebih tajam pada nilai *confidence* tinggi menunjukkan bahwa deteksi pada kelas tersebut kurang stabil jika hanya mempertimbangkan prediksi dengan *confidence* tinggi.



Gambar 10 *Precision-Recall Curve*

Grafik *precision-recall curve* ini menunjukkan performa model dalam mendeteksi objek dengan sangat baik dalam membedakan berbagai jenis sampah organik dan anorganik dengan nilai mAP50 sebesar 0.958 yang menandakan tingkat presisi dan *recall* yang tinggi secara keseluruhan. Sebagian besar kelas memiliki kurva *precision-recall* yang mendekati titik ideal yaitu 1 menunjukkan performa akurasi deteksi yang konsisten. Meskipun beberapa kelas seperti *organic_food_waste* dan *anorganic_rubber* memiliki performa sedikit lebih rendah namun model mampu mendeteksi objek dengan sangat akurat dan efisien.



Gambar 11 *F1-Confidence Curve*

Grafik *f1-confidence curve* menunjukkan bahwa model memiliki performa yang sangat baik dalam menyeimbangkan presisi dan *recall* dengan nilai F1-score rata-rata mencapai 0.93 pada confidence threshold sekitar 0.713. Hampir semua kelas mendapatkan nilai F1 yang tinggi yang menandakan konsistensi model dalam melakukan klasifikasi terhadap jenis sampah.

3.3 Pemeliharaan

Dikarenakan salah satu kelemahan dari model *waterfall* adalah kurangnya fleksibilitas dalam perubahan setelah tahap implementasi, maka pada penelitian ini tidak diperlukan pemeliharaan yang signifikan. Hal ini karena framework ultralytics YOLO yang digunakan tetap dapat berjalan dan dikembangkan lebih lanjut tanpa tergantung pada versi tertentu.

Permasalahan mengenai sampah organik maupun anorganik menjadi sangat serius mengingat dampaknya yang luar biasa pada lingkungan, untuk menindaklanjuti permasalahan tersebut diperlukan sebuah teknologi untuk membantu memilah sampah berdasarkan jenisnya supaya sampah dapat segera ditangani dan tidak menyebabkan masalah pada jangka waktu yang panjang.

Berdasarkan hasil yang telah dijabarkan diatas, model YOLOv9 menunjukkan performa yang cukup baik dalam mendeteksi dan mengklasifikasikan objek pada sampah organik dan anorganik. Penelitian yang dilakukan oleh Shenlin Liu mengembangkan EcoDetect-YOLO, dengan algoritma deteksi sampah berbasis *framework* YOLOv5s mendapatkan mAP50 mencapai 58,1%. Hasil ini menunjukkan bahwa model YOLOv9 memiliki performa yang lebih baik dan lebih stabil dalam mendeteksi objek sampah. Selanjutnya penelitian oleh Saurav Kumar yang menggunakan YOLOv3 yang dimana memperoleh mAP sebesar 94,99%. Hal ini menunjukkan bahwa model YOLOv9 memberikan performa yang sedikit lebih baik dalam mendeteksi objek. Selanjutnya penelitian oleh QiuHong Sun yang dimana menggunakan model YOLOv5-OCDS bersarkan YOLOv5 dan memperoleh mAP sebesar 5,3% dan untuk mAP50-95 sebesar 12,3% dari perbandingan model YOLOv5s dan YOLOv5-OCDS. Ini menunjukkan bahwa model YOLOv9 dapat menghasilkan performa yang lebih baik dalam mendeteksi objek pada berbagai jenis sampah.

IV. KESIMPULAN

Penelitian ini berhasil mengimplementasikan Model YOLOv9 untuk mendeteksi dan mengklasifikasikan sampah organik dan anorganik bersarkan jenisnya. Hasil evaluasi menunjukkan bahwa model mendapatkan akurasi yang tinggi dengan nilai rata-rata precision sebesar 0,937, recall 0,924, serta nilai mAP50 dan mAP50-95 sebesar 0,957 dan 0,888. Pada objek kertas dan besi memperoleh performa terbaik dengan mAP hampir sempurna lebih dari 98% sementara objek sisa makanan dan daun menunjukkan akurasi relatif lebih rendah. Secara keseluruhan YOLOv9 menunjukkan kinerja yang sangat baik dan dapat digunakan dalam pemilahan sampah berdasarkan jenisnya agar dapat membantu menangani masalah lingkungan dalam hal pemilahan sampah secara lebih baik.

DAFTAR PUSTAKA

- [1] C. A. Windanu and A. S. Fauzi, “Analisa komposisi bahan pupuk kompos dari sampah organik,” in *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, 2023, pp. 759–765.
- [2] I. S. Abidin and D. H. S. Marpaung, “Observasi penanganan dan pengurangan sampah di Universitas Singaperbangsa Karawang,” *Jurnal Justitia Jurnal Ilmu Hukum Dan Humaniora*, vol. 8, no. 4, pp. 872–882, 2021.
- [3] H. K. Astuti, “PEMBERDAYAAN EKONOMI KREATIF MELALUI DAUR ULANG SAMPAH PLASTIK (STUDI KASUS BANK SAMPAH KELURAHAN PAJU PONOROGO),” Apr. 25, 2022. doi: 10.31219/osf.io/6j7rv.
- [4] M. A. Lestari, M. B. Santoso, and N. Mulyana, “Penerapan teknik participatory rural appraisal (PRA) dalam menangani permasalahan sampah,” *Jurnal Penelitian dan Pengabdian Kepada Masyarakat (JPPM)*, vol. 1, no. 1, pp. 55–61, 2020.
- [5] N. Ekawandani, “PENGOMPOSAN SAMPAH ORGANIK (KUBIS DAN KULIT PISANG) DENGAN MENGGUNAKAN EM4,” Apr. 02, 2018. doi: 10.31227/osf.io/3gt26.

- [6] N. Azmin, I. Irfan, M. Nasir, H. Hartati, and St. Nurbayan, “Pelatihan Pembuatan Pupuk Kompos Dari Sampah Organik Di Desa Woko Kabupaten Dompu,” *Jompa Abdi: Jurnal Pengabdian Masyarakat*, vol. 1, no. 3, pp. 137–142, Sep. 2022, doi: 10.57218/jompaabdi.v1i3.266.
- [7] U. H. Marshush, E. Abubakar, and A. Rahmatullah, “Pengelolaan Sampah Anorganik di Kelurahan Tlogosari Kulon Kota Semarang,” *AJAD : Jurnal Pengabdian kepada Masyarakat*, vol. 3, no. 3, Dec. 2023, doi: 10.59431/ajad.v3i3.223.
- [8] T. Sutisna, A. R. Raharja, S. Solihin, E. Hariyadi, and V. H. C. Putra, “Penggunaan computer vision untuk menghitung jumlah kendaraan dengan menggunakan metode SSD (Single Shoot Detector),” *Innovative: Journal Of Social Science Research*, vol. 4, no. 2, pp. 6060–6067, 2024.
- [9] S. Liu, R. Chen, M. Ye, J. Luo, D. Yang, and M. Dai, “EcoDetect-YOLO: A Lightweight, High-Generalization Methodology for Real-Time Detection of Domestic Waste Exposure in Intricate Environmental Landscapes,” *Sensors*, vol. 24, no. 14, p. 4666, Jul. 2024, doi: 10.3390/s24144666.
- [10] S. Kumar, D. Yadav, H. Gupta, O. P. Verma, I. A. Ansari, and C. W. Ahn, “A Novel YOLOv3 Algorithm-Based Deep Learning Approach for Waste Segregation: Towards Smart Waste Management,” *Electronics (Basel)*, vol. 10, no. 1, p. 14, Dec. 2020, doi: 10.3390/electronics10010014.
- [11] Q. Sun, X. Zhang, Y. Li, and J. Wang, “YOLOv5-OCDS: An Improved Garbage Detection Model Based on YOLOv5,” *Electronics (Basel)*, vol. 12, no. 16, p. 3403, Aug. 2023, doi: 10.3390/electronics12163403.
- [12] V. Adi Kurniyanti and D. Murdiani, “Perbandingan Model Waterfall Dengan Prototype Pada Pengembangan System Informasi Berbasis Website,” *Jurnal Syntax Fusion*, vol. 2, no. 08, pp. 669–675, Aug. 2022, doi: 10.54543/fusion.v2i08.210.
- [13] D. T. Haniva, J. A. Ramadhan, and A. Suharso, “Systematic Literature Review Penggunaan Metodologi Pengembangan Sistem Informasi Waterfall, Agile, dan Hybrid,” *Journal of Information Engineering and Educational Technology*, vol. 7, no. 1, pp. 36–42, Jun. 2023, doi: 10.26740/jieet.v7n1.p36-42.
- [14] R. Padilla, W. L. Passos, T. L. B. Dias, S. L. Netto, and E. A. B. da Silva, “A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit,” *Electronics (Basel)*, vol. 10, no. 3, p. 279, Jan. 2021, doi: 10.3390/electronics10030279.
- [15] Rafael Padilla, Sergio Lima Netto, and Eduardo A. B. da Silva, “A Survey on Performance Metrics for Object-Detection Algorithms,” in *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, IEEE, Jul. 2020.
- [16] M. M. Huda, K. A. Prasetyo, M. A. R. Vieri, R. Wulanningrum, and M. A. D. W. Dara, “Identifikasi Mangga Berdasarkan Tingkat Kematangan Menggunakan Yolo 11,” in *Seminar Nasional Teknologi & Sains*, 2025, pp. 175–182.
- [17] M. M. NSA, R. Wulanningrum, and A. Sanjaya, “Implementasi YOLO Dalam Deteksi Jumlah Kendaraan,” in *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, 2024, pp. 1274–1281.