



Sistem Deteksi Objek Visual Sampah Organik Dan Anorganik Berbasis Algoritma YOLOv9

Dedy Adriansyah*, Muhammad Pajar Kharisma Putra

Fakultas Teknik dan Ilmu Komputer, Prodi Informatika, Universitas Teknokrat Indonesia, Bandar Lampung
Jl. Zainal Abidin Pagar alam No.9-11 Labuhan Ratu, Kec. Kedaton, Kota Bandar Lampung, Lampung, Indonesia

Email: ¹*dedy_adriansyah@teknokrat.ac.id, ²pajarkharisma@teknokrat.ac.id

Email Penulis Korespondensi: dedy_adriansyah@teknokrat.ac.id

Submitted: 16/12/2024; Accepted: 29/01/2025; Published: 31/01/2025

Abstrak—Efisiensi dalam pengelolaan sampah merupakan tantangan utama di kota-kota modern. Dengan banyaknya manusia yang membuang sampah organik maupun anorganik maka dibutuhkanlah solusi agar sampah dapat disortir dengan baik. Oleh karena itu pada penelitian ini peneliti bertujuan memanfaatkan teknologi computer vision berbasis algoritma YOLOv9 untuk mendeteksi dan memilah sampah organik dan anorganik. Dengan menggunakan dataset sebesar 6.747 gambar dari platform Roboflow, sistem ini dilatih untuk mengenali berbagai jenis sampah melalui metode pelabelan bounding box. Algoritma YOLOv9 dilengkapi dengan fitur Programmable Gradient Information (PGI) dan Generalized Efficient Layer Aggregation Network (GELAN), yang memberikan performa unggul dalam hal akurasi dan kecepatan performa sistem. Hasil Pelatihan model menunjukkan bahwa YOLOv9 memiliki nilai presisi 0.83% , recall 0.85%, dan mAP 0.8% menjadikan model handal dalam mendeteksi objek. Namun, terdapat beberapa kelemahan, seperti penurunan akurasi pada gambar buram, tumpang tindih objek, dan warna yang memiliki kemiripan serupa dapat memengaruhi hasil deteksi hingga 20-30%. Dibandingkan dengan SSD MobileNet v2, YOLOv9 unggul dalam akurasi, presisi dan F-1 Score dengan hasil berada pada nilai Accuracy 58%, Precision 81%, F1- Score 69%. Pada hasil testing Intersection over Union (IoU) menghasilkan keakuratan yang sangat baik sebesar 0.96%. Penelitian ini merekomendasikan peningkatan melalui augmentasi data dan integrasi sensor untuk meningkatkan performa diberbagai kondisi pencahayaan. Algoritma ini memiliki potensi dapat diterapkan dalam pengelolaan sampah berbasis teknologi, mendukung efisiensi daur ulang, mengurangi kesalahan manusia, dan memberikan dampak positif terhadap lingkungan secara global.

Kata Kunci: YOLO; Deteksi; Sampah; Digital Image Processing; Intersection over Union (IoU).

Abstract—Efficiency in waste management is a major challenge in modern cities. With so many people throwing away organic and inorganic waste, a solution is needed so that the waste can be sorted properly. Therefore, in this research, researchers aim to utilize computer vision technology based on the YOLOv9 algorithm to detect and sort organic and inorganic waste. Using a dataset of 6,747 images from the Roboflow platform, this system was trained to recognize various types of waste using the bounding box labeling method. The YOLOv9 algorithm is equipped with Programmable Gradient Information (PGI) and Generalized Efficient Layer Aggregation Network (GELAN) features, which provide superior performance in terms of accuracy and speed of system performance. The model training results show that YOLOv9 has a precision value of 0.83%, recall of 0.85%, and mAP of 0.8%, making the model reliable in detecting objects. However, there are several weaknesses, such as decreasing accuracy in blurry images, overlapping objects, and colors that have similar similarities, which can affect detection results by up to 20-30%. Compared to SSD MobileNet v2, YOLOv9 is superior in accuracy, precision and F-1 Score with results in Accuracy values of 58%, Precision 81%, F1-Score 69%. The Intersection over Union (IoU) test results produce excellent accuracy of 0.96%. This research recommends improvements through data augmentation and sensor integration to improve performance in various lighting conditions. This algorithm has great potential to be applied in technology-based waste management, supporting recycling efficiency, reducing human error, and providing a positive impact on the environment globally.

Keywords: YOLO; Detection; Trash; Digital Image Processing; Intersection over Union (IoU).

1. PENDAHULUAN

Sampah adalah sebuah masalah yang sering di temukan di seluruh Dunia terutama di Indonesia. Faktor pendukung pertumbuhan sampah adalah gaya hidup manusia yang ingin efisien setiap harinya menyebabkan penumpukan sampah terus terjadi, seperti contoh penggunaan kantong plastik [1]. Permasalahan penumpukan sampah ini sering terjadi akibat dari pengelolaan sampah yang dilakukan kurang efektif dan kurangnya masyarakat dan pemerintah akan pengelolaan limbah sampah, oleh karena itu masyarakat dan pemerintah sangat berperan dalam mengurangi sampah dengan memberikan sosialisasi akan bahaya sampah disekitar kehidupan masyarakat dan melakukan berbagai pencegahan sebelum menjadi sebuah permasalahan lebih lanjut [2], [3]. Kekurangan ini terjadi dikarenakan tidak adanya hukum yang tegas dan tempat penampungan sampah yang kurang memadai sehingga memicu masyarakat untuk membuang sampah sembarangan [4].

Indonesia merupakan negara nomor 2 penyumbang sampah plastik terbesar di dunia setelah negara Cina. Shanghai Cina menghasilkan hampir 9 juta ton sampah per tahun, dan jumlah ini terus meningkat. Cina sendiri telah menggunakan berbagai cara untuk mengurangi permasalahan di negaranya dengan berbagai program contohnya adalah tempat pengumpulan berbagai kategori sampah, kendaraan pengangkut berbagai kategori sampah dan program televisi [5]. Di Indonesia sendiri sebesar 3 juta ton lebih sampah plastik dibuang oleh masyarakat Indonesia kebanyakan dari sampah tersebut dibuang menuju laut dan sungai. Kementerian Lingkungan Hidup menyatakan bahwa masyarakat Indonesia menghasilkan sekitar 28.4 ribu ton sampah plastik/hari.

Sedangkan Indonesia Solid Waste Association (InsWA) menyatakan bahwa jumlah sampah plastik di Indonesia telah mencapai angka 5.4 juta ton/tahun produksi sampah di Indonesia [6]. Sampah tersebut dapat menyebabkan pencemaran air, terjadinya banjir, menghambat aliran air dan mengurangi ekosistem biota sungai dan laut [7], [8]. Produksi sampah organik dan anorganik dari sampah yang tidak dikelola dengan baik akan menimbulkan kerusakan lingkungan. Oleh karena itu diperlukan pengelolaan yang baik. Salah satu program yang telah dilakukan yaitu program 3R (reuse, reduce dan recycle) ini merupakan kegiatan peningkatan kesadaran masyarakat, dalam upaya pemilahan sampah yang dimulai dari rumah. Masyarakat dididik bagaimana mengolah sampah agar dapat dimanfaatkan kembali [9], [10].

Seiring dengan perkembangan teknologi, kebutuhan akan sistem pendeteksian sampah organik dan anorganik mulai dipergunakan oleh berbagai negara, dan permintaan terhadap sistem kecerdasan buatan meningkat dengan cepat. Pada tahap ini peneliti menggunakan computer vision adalah sebuah penemuan di bidang komputer yang digunakan untuk membuat sistem yang hampir menyerupai fungsi sistem visual manusia pada umumnya. computer vision memungkinkan peneliti untuk menyelesaikan tugas dan untuk membuat suatu keputusan tentang objek fisik nyata yang didapat dari perangkat [11].


Pengolahan citra digital adalah sebuah proses gambar dua dimensi menggunakan sistem komputer. Pengolahan yang dimaksud yaitu proses gradasi, memodifikasi, maupun memanipulasi karakteristik citra agar hasil dari pengolahan tersebut sesuai dengan apa yang diinginkan dan dapat dimengerti oleh citra manusia. Pengolahan citra digital ini digunakan dalam tujuan deteksi sampah organik dan anorganik [12]. untuk mendapatkan data sampah tersebut peneliti menggunakan situs Roboflow. Roboflow memungkinkan peneliti mempartisi kumpulan data selama pemrosesan dengan menggunakan kotak pembatas (bounding box) untuk memberi anotasi dan menandai objek yang dikenali. Untuk melakukan pengujian deteksi objek, peneliti memerlukan kumpulan data. Pada fase ini, peneliti mencari dan mengumpulkan sekumpulan data gambar yang sesuai untuk pendeteksian objek sampah organik dan anorganik [13].

Pendeteksian objek sampah organik dan anorganik ini peneliti menggunakan arsitektur algoritma YOLO (You Only Look Once) terutama yaitu YOLOv9. Algoritma satu tahap, seperti YOLO memfasilitasi deteksi dan klasifikasi target di dalam gambar, sehingga mencapai kecepatan deteksi yang luar biasa membuat algoritma YOLO yang memiliki performa sangat baik dalam pengenalan citra dan identifikasi serta akurat dalam mendeteksi objek [14], [15]. Algoritma YOLO telah secara signifikan meningkatkan performa dalam deteksi objek melalui peningkatan arsitektur Generalized Efficient Layer Aggregation Network (GELAN) dan penerapan augmentasi pelatihan Programmable Gradient Information (PGI), sehingga mencapai kinerja yang unggul dibandingkan dengan pendahulunya [16]. Dalam bidang deteksi objek, arsitektur algoritma YOLO telah mengalami kemajuan evolusi yang signifikan. Pada Penelitian ini, Peneliti menggunakan beberapa referensi jurnal seperti “Deteksi Sampah Plastik Menggunakan Algoritma Yolov5”, “Implementasi YOLO versi 3 untuk Mengidentifikasi dan Mengklasifikasi Sampah Kantor berbasis NVIDIA Jetson Nano”, “Deteksi Sampah Botol Plastik di Perairan Menggunakan YOLO v4- Tiny” dan referensi lainnya dalam membantu penelitian ini [11], [17], [18], [19], [20]. Referensi pada penelitian sebelumnya telah meneliti penggunaan algoritma YOLO dalam mendeteksi sampah dan penggunaannya pada lingkungan masyarakat, mendeteksi sampah plastik dan performa deteksi sampah secara real-time. Pada penelitian ini GAP Research atau penelitian baru yang akan diteliti adalah menambahkan sampah organik pada klasifikasi sampah yang akan dideteksi, melihat hasil nilai algoritma YOLO dalam membandingkan sampah organik dan anorganik, dan bagaimana hasil performa sampah organik dan organik dalam rentang Intersection over Union (IoU). Penelitian ini bertujuan memberikan kontribusi pada pengembangan teknologi computer vision dalam deteksi sampah organik dan anorganik dengan memanfaatkan algoritma YOLOv9 dan bagaimana performa hasil, manfaat teknologi ini pada lingkungan masyarakat.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan kerangka deteksi YOLOv9 sebagai model. Dataset dan Pelabelan data objek yang digunakan untuk penyelidikan ini terdiri dari berbagai kumpulan data terkait limbah sampah yang dikumpulkan melalui platform Roboflow. Arsitektur model YOLOv9 dilakukan menggunakan jaringan berbasis cloud yang difasilitasi oleh platform Kaggle. Prosedur pelatihan model mencakup anotasi data menggunakan teknik augmentasi gambar yang dirancang untuk meningkatkan akurasi, presisi dan kinerja keseluruhan model. Hasil evaluasi yang diperoleh dari penelitian ini bertujuan untuk memberikan penilaian terhadap model dalam mengidentifikasi limbah sampah organik dan anorganik. Untuk alur penelitiannya dapat dilihat pada gambar 1.



Gambar 1. Alur Penelitian

2.2 Pengumpulan Data

Dataset yang digunakan berasal dari Roboflow Universe, roboflow merupakan tempat bermacam kumpulan miliaran data sekunder untuk mendorong evaluasi kinerja model deteksi objek untuk menguji kemampuan model untuk memberikan tolok ukur multidomain yang beragam untuk membantu peneliti menguji kemampuan hasil training model mereka dengan data kehidupan nyata [21].

Dataset yang dipakai merupakan berbagai macam sampah organik dan anorganik kecuali sampah B3 (Bahan Berbahaya Beracun). Pada teknik pengumpulan dataset yang dipakai menggunakan berbagai macam dataset dengan dua klas value yaitu sampah organik dan anorganik berupa 6.747 dataset. Jenis sampah organik seperti ini bisa terurai secara alamiah di alam, contohnya sisa-sisa makhluk hidup seperti tumbuhan dan hewan. Sedangkan sampah anorganik terdiri dari bahan yang bukan berasal dari hewan dan tumbuhan serta tidak mudah hancur secara alamiah di alam, seperti contoh kaleng, botol plastik, barang elektronik dan alat perkakas[22], [23]. Dibutuhkan bantuan alat mesin penghancur untuk dapat teruraikan dengan baik. Untuk contoh data dapat dilihat pada Gambar 2 dan Gambar 3 :




Gambar 2. Contoh dataset sampah Organik



Gambar 3. Contoh dataset sampah Anorganik

2.3 Pelabelan Model

Selanjutnya adalah melakukan anotasi pelabelan pada setiap gambar. Proses ini melibatkan penandaan area tertentu dalam gambar yang berisi dataset sampah organik dan anorganik, menggunakan bounding box yang mengelilingi objek tersebut secara tepat. Untuk menghasilkan output bounding box, sistem memproses gambar input menggunakan konvolusi. Hasil akhirnya adalah ukuran bounding box dengan format $SxSx(B*5+C)$, di mana B menunjukkan jumlah bounding box dalam gambar, dan C merupakan jumlah kelas pada model yang dapat dideteksi. Nilai B akan dikalikan dengan angka 5 (lima) dikarenakan sebuah bounding box memiliki 5 atribut yang perlu disimpan, diantaranya adalah Lebar (width), Tinggi (height), Koordinat X, Koordinat Y dan Confidence score (Nilai probabilitas sebuah bounding box dalam mendeteksi sebuah objek) [17]. Setiap bounding box diberi label yang sesuai dengan tujuan agar model dapat mengenali dan memahami pola-pola visual yang ada pada objek. Gambar 4 berikut merupakan bagian proses pelabelan menggunakan platform roboflow.




Gambar 4. Pelabelan dataset menggunakan platform Roboflow

Setiap box diberi anotasi berdasarkan kelasnya. Karena keakuratan anotasi memengaruhi kemampuan model algoritma untuk mendeteksi dan mengenali objek dengan tepat, keakuratan ini sangat penting [24]. Model

dapat belajar dengan baik dan bekerja lebih baik terhadap anotasi yang tepat dan konsisten. Pada Gambar 5 menunjukkan gambar dataset yang belum dilabel dan pada Gambar 6 menunjukkan gambar dataset yang telah dilabel dan bounding box menggunakan platform roboflow.



Gambar 5. Objek dataset sampah organik dan anorganik sebelum dilabel



Gambar 6. Objek dataset sampah organik dan anorganik setelah dilabel dan bounding box

2.4 Arsitektur Model Algoritma YOLO

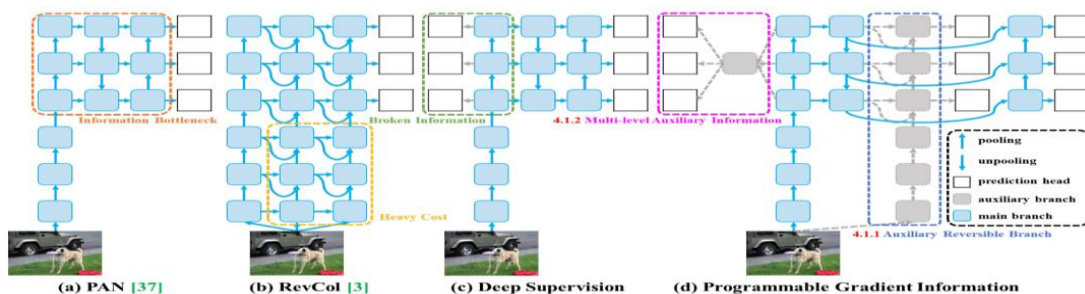
You Only Look Once terutama YoloV9 menggunakan metodologi yang menggabungkan Programmable Gradient Information (PGI) dan Generalized Efficient Layer Aggregation Network (GELAN), untuk secara efektif menghadapi masalah yang terkait dengan kehilangan data dan efisiensi komputasi di bidang visi komputer. Metode ini mengintegrasikan cabang reversibel tambahan yang bertujuan menghasilkan gradien tanpa menimbulkan biaya inferensi tambahan terutama melalui penggabungan data tambahan multi-level untuk menghindari degradasi informasi yang biasa ditemui dalam deep networks dan menjamin pembaruan parameter yang lebih konsisten. PGI dalam kapasitas model membantu mempertahankan akurasi, sementara secara bersamaan mengurangi jumlah parameter dan operasi. Proses ini diulang untuk setiap iterasi selama pelatihan, dengan PGI terus menerus menyesuaikan gradien berdasarkan target spesifik [25]. PGI mengintegrasikan tiga komponen utama untuk meningkatkan efisiensi dan akurasi model:

1. Cabang Utama: Dirancang untuk inferensi yang cepat dan efisien tanpa memerlukan komponen tambahan, menjaga kinerja tetap optimal.
2. Cabang Bantu Reversible: Memastikan gradien yang stabil dan penyesuaian parameter yang baik, sekaligus mengurangi kehilangan informasi dalam jaringan mendalam. Cabang ini fleksibel untuk diintegrasikan tanpa memengaruhi kecepatan.
3. Informasi Bantu Multi-Level: Menggabungkan data dari berbagai lapisan untuk mencegah kehilangan informasi, meningkatkan pemahaman model, dan akurasi prediksi pada objek dengan ukuran beragam [26].

Keuntungan dari PGI adalah:

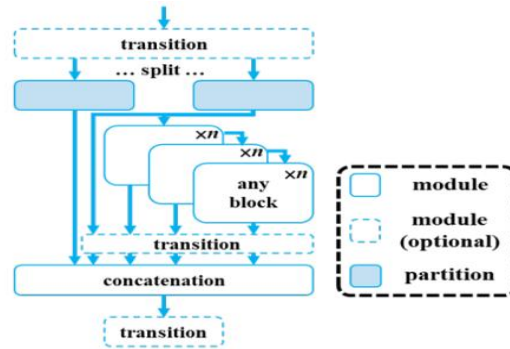
1. Kontrol Lebih Besar: Dapat memprogram pembelajaran sesuai kebutuhan aplikasi.
2. Fleksibilitas: Bisa menangani berbagai masalah seperti ketidakseimbangan kelas atau fokus pada objek kecil.
3. Efisiensi Pelatihan: Mengarahkan pembaruan parameter untuk lebih relevan dengan tugas.

Arsitektur pemodelan Programmable Gradient Information (PGI) dapat dilihat pada Gambar 7.



Gambar 7. Arsitektur model Programmable Gradient Information (PGI)

Sementara itu GELAN menggunakan unit komputasi yang mengurangi kebutuhan memori sambil mempertahankan presisi dalam inferensi, terutama dalam arsitektur ringan. Arsitekturnya yang dapat disesuaikan memungkinkan jaringan untuk mengakomodasi berbagai tugas dalam platform komputasi, yang dirancang dengan perencanaan jalur gradien, dengan mengintegrasikan informasi dari berbagai layer. GELAN meningkatkan kemampuan model untuk menangkap fitur penting dari gambar, kecepatan inferensi, dan akurasi membuatnya sangat cocok untuk deteksi objek. contoh arsitektur gelan dapat dilihat dalam Gambar 8.



Gambar 8. Arsitektur model Generalized Efficient Layer Aggregation Network (GELAN)

Proses pelatihan model YOLOv9 dilakukan menggunakan platform Kaggle, menggunakan CPU sebagai dasar pelatihan, setelah itu dataset sampah organik dan anorganik diunggah dan dipreprocess untuk memastikan kualitas data. Selama fase pelatihan, parameter seperti epoch, batch size, dan image size disesuaikan untuk optimalisasi yang ditampilkan pada Tabel 1.

Tabel 1. Parameter Pelatihan Yolo

No	Parameter	Nilai
1	Epoch	200
2	Batch Size	8
3	Image Size	320

Epoch yang digunakan sebanyak 200 memungkinkan model dapat memperbaiki parameternya berdasarkan data error yang dihasilkan setelah memproses satu siklus penuh dataset, semakin banyak epoch yang diatur semakin bagus model dalam perbaikan dataset model nantinya dan semakin akurat. Pengaturan batch size sebesar 8 diharapkan agar pada setiap iterasi, model akan memproses 8 gambar sekaligus sebelum melakukan proses backpropagation. Backpropagation adalah metode untuk menghitung bagaimana perubahan bobot atau jaringan saraf dalam memengaruhi keakuratan prediksi. Model bekerja dengan menghitung kerugian secara mundur, lapis demi lapis, untuk meminimalkan kerugian secara keseluruhan. Penggunaan batch size yang lebih besar memungkinkan pelatihan yang lebih cepat, karena lebih banyak data yang diproses dalam satu waktu. Image size 320x320 dipilih karena komputasi yang lebih cepat dan memungkinkan model dapat melakukan iterasi lebih banyak dalam waktu yang sama. Algoritma YOLOv9 memproses seluruh gambar cukup sekali dimulai dengan melakukan input Layer Mengambil gambar dengan ukuran tetap 320x320 piksel, lalu mengubahnya menjadi tensor untuk mempercepat proses training. selanjutnya melakukan Convolutional Layers yaitu Mengekstraksi fitur gambar, seperti tepi, bentuk, dan tekstur, melalui beberapa lapisan konvolusi (CNN). berikutnya melakukan Flatten Layer untuk Mengubah data multidimensi menjadi vektor satu dimensi Dan terakhir Fully Connected Layers yaitu Menggabungkan informasi dari lapisan sebelumnya untuk memprediksi bounding box dan kelas objek secara langsung.

2.5 Evaluasi Model

Evaluasi model merupakan parameter penilaian untuk menguji akurasi model, tingkat confident dan langkah kritis untuk memastikan bahwa model klasifikasi terhadap data baru yang telah dilatih berfungsi dengan baik. Proses evaluasi dimulai dengan menguji model pada dataset validasi yang belum pernah dilihat sebelumnya untuk mengukur performa deteksi dalam situasi nyata. Setelah model dilatih, model dapat dievaluasi dengan menggunakan dataset, hasil model dapat dievaluasi dengan menggunakan metrik evaluasi seperti Confusion Matrix, Precision, Accuracy, Recall, dan F1-Score. Pengukuran kinerja confusion matrix menggunakan 4 istilah yang akan menunjukkan hasil dari proses klasifikasi [13]:

- a. Confusion Matrix adalah alat yang digunakan untuk mengevaluasi kinerja model klasifikasi dengan menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas. Matrix ini terdiri dari empat komponen utama:
 1. True Positive(TP) = Total dari data yang positif dan terklasifikasi oleh sistem dengan benar.
 2. True Negative(TN) = Total dari data yang positif dan terklasifikasi oleh sistem dengan salah.
 3. False Positive(FP) = Total dari data yang negatif dan terklasifikasi oleh sistem dengan benar.

4. False Negative(FN) = Total dari data yang negatif dan terklasifikasi oleh sistem dengan salah.

Confusion matrix memberikan informasi tentang kinerja model dalam hal pengenalan setiap kelas dan membantu dalam menganalisis kesalahan yang dibuat oleh model.

- b. Precision adalah metrik yang menilai seberapa akurat model dalam membuat prediksi positif. Precision mengukur proporsi dari prediksi positif yang benar di antara semua prediksi positif (1):

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positive}} \quad (1)$$

- c. Recall mengukur tingkat keberhasilan dan seberapa baik model dalam mendeteksi semua nilai positif yang ada dalam dataset. Adapun rumus untuk melakukan perhitungan recall seperti pada rumus berikut (2):

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}} \quad (2)$$

- d. mAP atau Mean Average Precision (mAP) adalah metrik yang digunakan untuk mengukur kinerja model dalam mendeteksi objek atau gestur tangan di berbagai kelas. mAP adalah rata-rata dari Average Precision (AP) untuk setiap kelas dalam dataset. AP dihitung dengan mengukur precision dan recall pada berbagai ambang batas deteksi untuk setiap kelas, dan kemudian menghitung rata-ratanya (3):

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3)$$

dimana N menunjukkan presisi Rata-rata untuk setiap kelas individu. Perhitungan mAP dilakukan dengan menggunakan nilai Intersection over Union (IOU).


- e. Accuracy adalah hasil akurasi untuk mendefinisikan tingkat dari dekatnya nilai aktual dengan nilai hasil prediksi. Semakin tinggi tingkat akurasi, semakin baik kinerja metode [13]. Adapun rumus untuk melakukan perhitungan akurasi seperti pada rumus (4):

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

- f. F1-Score memberikan keseimbangan antara tingkat prediksi benar (Precision) dan cakupan deteksi positif (Recall).

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

- g. Intersection over Union (IoU) adalah metode evaluasi yang digunakan untuk mengukur akurasi deteksi objek dalam konteks dataset. Intersection over Union (IoU) digunakan untuk mengevaluasi seberapa baik prediksi bounding box model cocok dengan ground truth. Bounding box merupakan kotak pembatas yang bertujuan untuk mengidentifikasi posisi objek yang terdapat pada gambar. Setelah setiap objek yang telah diberi bounding box memiliki sebuah kelas, setiap kelas dikelompokkan agar bounding box dapat mengklasifikasi jenis kelas apa yang terdeteksi pada algoritma YOLO tersebut [17]. Contoh Rumus IoU dan contoh hasil rentang bounding box yang baik dapat dilihat pada Gambar 9.



Gambar 9. Gambar rumus IoU dan rentang hasil IoU yang buruk, bagus dan terbaik [27]

Pada Gambar 9 Di mana (a) adalah area bounding box prediksi dan (b) adalah area bounding box dan ground truth. Nilai IoU berkisar antara 0 hingga 1, nilai 1 berarti prediksi cocok dan sejajar dengan ground truth. Dalam konteks pengenalan objek, IoU sering digunakan untuk menentukan apakah prediksi dianggap benar atau salah berdasarkan ambang batas tertentu, misalnya $\text{IoU} > 0.5$ dianggap sebagai prediksi yang benar karena hasil yang cukup tumpang tindih dengan bounding box [28].

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

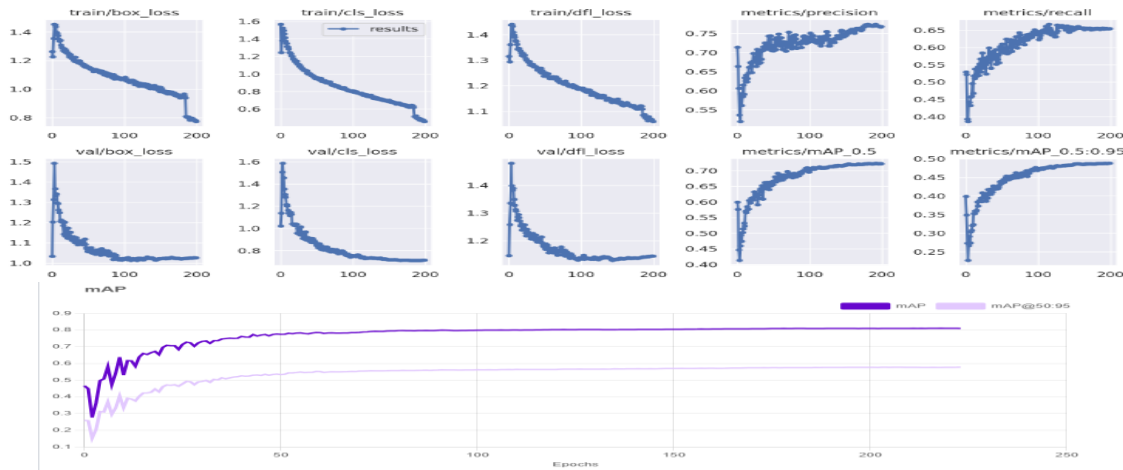
Hasil yang didapat setelah melakukan implementasi model YOLOv9 dalam kurun waktu **6 jam** menggunakan platform kaggle dalam mendeteksi kelas limbah sampah organik dan anorganik didapat memiliki performa yang cukup bagus dalam hal keakuratan deteksi. Model mampu mendeteksi limbah sampah dengan tingkat akurasi

cukup baik, di mana nilai precision, recall dan nilai mAP mendapatkan 0.6 ke atas atau diatas 60%. Hasil pelatihan model dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pelatihan Kinerja Model

Class	Precision	Recall	mAP50
Organik	0.696	0.602	0.648
Anorganik	0.84	0.705	0.798
All	0.836	0.853	0.88

Hasil dalam skor prediksi yang ditampilkan dalam kotak tabel menunjukkan nilai precision recall dan mAP pada hasil tersebut kemampuan model dalam membuat prediksi yang cukup akurat terhadap dua limbah yang dianalisis. Hasil diatas juga menunjukkan bahwa sampah anorganik memberikan nilai hasil yang lebih baik dari sampah organik. Selanjutnya hasil penilaian pelatihan dan validasi yang berfungsi untuk mengevaluasi performa model selama prosedur pelatihan, menunjukkan penurunan grafik pelatihan dan validasi seiring bertambahnya jumlah epoch. Hasil ini dapat dilihat pada Gambar 10 hasil menandakan kemahiran model dalam membedakan pola data dan memberikan wawasan tentang potensi kejadian overfitting atau underfitting. Semakin bagus garis lengkung pada grafik menandakan model training pada algoritma yang di proses semakin baik dan semakin akurat.




Gambar 10. Grafik training, validation loss dan mAP.

3.2 Evaluasi Matrix

Setelah menguji performa deteksi pada pelatihan model YOLOv9, peneliti membandingkannya dengan algoritma SSD MobileNetv2 menggunakan dataset yang sama. SSD MobileNetv2 lebih menunjukkan performa keunggulan dalam kecepatan deteksi, meskipun tingkat akurasi sedikit lebih rendah dibandingkan YOLOv9. Hal ini menunjukkan bahwa SSD lebih cocok untuk aplikasi yang membutuhkan kecepatan, sementara YOLOv9 lebih unggul dalam akurasi. Selanjutnya peneliti melakukan evaluasi kinerja operasional dua arsitektur deteksi objek, yaitu YOLO v9 dan SSD MobileNet v2, dinilai dari seluruh metrik accuracy, precision, Recall, dan F1-Score. Matrik evaluasi perbandingan model dapat dilihat pada Tabel 3 dan Gambar 11 dibawah berikut.


Tabel 3. Matrix Evaluasi Model.

Models	Accuracy	F1-Score	Precision	Recall
YOLOv9	0.58	0.69	0.81	0.61
SSD MobileNet	0.46	0.63	0.46	1.0



Gambar 11. Diagram hasil perbandingan matrik kinerja model YOLOv9 dengan SSD MobileNetv2.

Pada Gambar 11 dapat dilihat dengan jelas perbandingan 2 model arsitektur terhadap hasil metrik accuracy, precision, Recall, dan F1-Score. YOLO v9 menunjukkan kinerja yang unggul dari SSD MobileNetv2 dengan hasil nilai YOLOv9 yaitu Accuracy 58%, Precision 81%, F1- Score 69% dan Recall 61%. Hasil matrix evaluasi ini menunjukkan bahwa model menunjukkan tingkat efektivitas yang cukup baik dalam deteksi objek yang konsisten. Sebaliknya, SSD MobileNetv2 mencapai akurasi 46%, presisi 46%, F1-Score 63% dan nilai Recall 100%, walaupun disini Recall 100% menandakan bahwa SSD MobileNetv2 mendeteksi semua cakupan objek deteksi pada gambar. Meskipun model SSD MobileNetv2 ini menunjukkan tingkat Recall yang relatif tinggi, penurunan kapasitas memori accuracy dan precision menunjukkan bahwa terkadang model dapat mengalami masalah dalam mengenali objek tertentu, menghasilkan kinerja keseluruhan yang lebih rendah dibandingkan dengan YOLOv9. YOLOv9 dianggap sebagai model yang baik dibandingkan dengan SSD MobileNetv2. Selanjutnya adalah perhitungan nilai IoU yang bertujuan menunjukkan sejauh mana model dapat mendeteksi objek. Hasil nilai IoU yang tinggi (mendekati nilai 1) mengindikasikan bahwa prediksi sangat akurat, dengan tingkat kesesuaian yang besar antara kotak prediksi dan ground truth. Sebaliknya, IoU yang rendah menunjukkan bahwa prediksi kurang tepat, yang bisa disebabkan oleh ketidaksesuaian dalam posisi, ukuran atau bentuk bounding box dibandingkan dengan ground truth. Peneliti menentukan batas IoU menggunakan threshold dengan nilai 0.8 karena mampu mencapai ambang keseimbangan mendeteksi objek.



Gambar 12. Contoh hasil nilai IoU pada objek.

Bisa dilihat pada Gambar 12, objek kotak karton bounding box prediksi (warna biru) cukup mendekati ground truth (warna hijau). IoU cenderung tinggi karena kotak prediksi hampir sepenuhnya tumpang tindih dengan ground truth. Pada objek buah alpukat (organik), prediksi tampaknya mencakup semua objek dengan akurasi yang baik, tetapi ada sedikit deviasi pada posisi kotak prediksi, yang dapat menurunkan hasil nilai pada IoU. Pada objek buah apel, prediksi terlihat memisahkan objek segar dan busuk dengan cukup baik. Namun, jika ada perbedaan ukuran atau posisi bounding box, hal ini bisa menyebabkan penurunan IoU.

3.3 Hasil Testing Performa YOLOv9

Sistem yang dilatih menggunakan metode YOLOv9 diuji untuk mengevaluasi kinerjanya dalam mendeteksi objek tertentu, sebagai hasil testing objek-objek organik dan anorganik. Pengujian dilakukan terhadap sejumlah dataset gambar, dan hasilnya menunjukkan variasi dalam keberhasilan deteksi. Pada Gambar 13 menunjukkan hasil performa pelatihan YOLOv9 dengan hasil yang cukup baik dan akurat.



Gambar 13. Hasil testing objek benar dan akurat.

Pada sistem mampu mengidentifikasi objek organik seperti buah kering dengan tingkat keakuratan tinggi, berkisar antara 0.37 hingga 0.95. Bounding box terlihat sesuai dan mencakup objek dengan baik, seperti irisan jeruk, nanas, dan kiwi. Sama halnya dengan objek anorganik sistem mengidentifikasi hasil objek dengan nilai 0.80 hingga 0.97.

Hal ini menunjukkan performa deteksi yang baik. Namun pada Gambar 14, terdapat kasus di mana sistem menghasilkan prediksi yang kurang tepat, tidak terdeteksi maupun eror.



Gambar 14. Hasil data eror

Beberapa objek yang seharusnya diklasifikasikan sebagai gambar organik berhasil dideteksi sebagai anorganik maupun sebaliknya, sebagai contoh terdapat satu objek pada pucuk tomat yang salah baca anotasi diklasifikasikan sebagai anorganik dengan skor 0.61. Adapun kepadatan objek dalam gambar kaleng makanan menyebabkan tumpang tindih kotak pembatas (bounding box) dan beberapa prediksi yang tidak optimal. ini dapat disebabkan oleh faktor warna atau fitur visual objek yang mirip, yang membingungkan model, gambar buram/tidak jelas, objek memiliki bentuk serupa seringkali salah diklasifikasikan, Objek terpotong dan objek yang tidak terlihat utuh membuat sistem gagal mendeteksi dengan baik dan menyebabkan kesalahan pembacaan anotasi label.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa penggunaan algoritma YOLOv9 dalam sistem deteksi sampah organik dan anorganik memberikan hasil yang cukup baik dan akurat. Performa, sistem ini mampu mencapai tingkat presisi, recall, dan mAP yang tinggi, masing-masing berada di atas 60%. YOLO v9 menunjukkan kinerja yang unggul dari SSD MobileNetv2 dengan performa hasil yaitu Accuracy 58%, Precision 81%, F1- Score 69% dan Recall 61%. Sistem ini mampu bekerja dengan baik dalam kondisi gambar yang jelas dan tidak terhalang. Meskipun begitu, terdapat beberapa tantangan seperti akurasi yang menurun sebesar 20% - 40% pada gambar buram, tumpang tindih objek, warna objek yang serupa yang dapat membingungkan objek dalam mendeteksi sampah tersebut organik atau anorganik dan objek yang tidak terlihat utuh. Hal ini menunjukkan bahwa meskipun sistem memiliki kinerja deteksi yang baik, masih diperlukan perbaikan lebih lanjut untuk mengatasi keterbatasan tersebut. Perbaikan dapat dilakukan melalui augmentasi data, transfer learning, melatih kembali sistem dengan dataset yang lebih banyak dan mengatur sistem pelatihan dengan lebih banyak seperti epoch, batch size, dan image size. Sistem YOLO ini dapat memudahkan pemerintah terutama tempat pembuangan akhir (TPA) maupun petugas kebersihan dalam memilah dan memproses sampah organik dan anorganik untuk mengantisipasi terjadinya penumpukan sampah di lingkungan masyarakat terutama di perkotaan, sungai maupun TPA sekaligus dengan cara memantau dan mendapatkan informasi menggunakan kamera CCTV atau AI yang dikonfigurasi dengan algoritma YOLO sebagai pendeteksi sampah.

REFERENCES

- [1] A. Binawan, "Garbage Care as a Way for Eco-Spiritual Care in a Multifaith Society in Indonesia," *Religions*, vol. 14, no. 4, 2023, doi: 10.3390/rel14040509.
- [2] N. Fauziah, S. Sukaris, A. R. Rahim, and R. Jumadi, "Peningkatan Kepedulian Masyarakat Terhadap Lingkungan Khususnya Dalam Permasalahan Sampah," *DedikasiMU(Journal Community Serv.,* vol. 2, no. 4, p. 561, 2020, doi: 10.30587/dedikasimu.v2i4.2053.
- [3] L. Julia Lingga, M. Yuana, N. Aulia Sari, H. Nur Syahida, and C. Sitorus, "Sampah di Indonesia: Tantangan dan Solusi Menuju Perubahan Positif," *Innov. J. Soc. Sci. Res.*, vol. 4, pp. 12235–12247, 2024.
- [4] K. Avitadira, N. Indrawati, and K. Kunci, "Upaya Mengatasi Permasalahan Sampah di DKI Jakarta Tahun 2021 : Tinjauan Collaborative Governance," *NeoRepublica J. Ilmu Pemerintah.*, vol. 5, no. 1, pp. 49–69, 2023, [Online]. Available: <http://neorespublica.uho.ac.id/index.php/journal/article/view/147>
- [5] M. H. Zhou, S. L. Shen, Y. S. Xu, and A. N. Zhou, "New policy and implementation of municipal solid waste classification in Shanghai, China," *Int. J. Environ. Res. Public Health*, vol. 16, no. 17, 2019, doi: 10.3390/ijerph16173099.
- [6] N. W. Aisha, "Pengaruh Bank Sampah Terhadap Jumlah Sampah Plastik di Indonesia," *J. Altern. - J. Ilmu Hub. Int.*, vol. 14, no. 1, pp. 68–73, 2023, doi: 10.31479/jualter.v14i1.57.
- [7] H. D. Atmanti, "Kajian Pengelolaan Sampah Di Indonesia," *Pembang. Berkelanjutan di Indones. dalam Mewujudkan Tujuan Ekon. Inklusif*, vol. 2, pp. 15–27, 2019.
- [8] M. F. Rahman and B. Bambang, "Deteksi Sampah pada Real-time Video Menggunakan Metode Faster R-CNN," *Appl. Technol. Comput. Sci. J.*, vol. 3, no. 2, pp. 117–125, 2021, doi: 10.33086/atcsj.v3i2.1846.
- [9] L. Siswati, H. Eterudin, D. Setiawan, A. T. Ratnaningsih, and A. Yandra, "Penyadaran Kepada Ibu Rumah Tangga dalam



- Pemisahan Sampah Organik dan Anorganik Rumah Tangga di Kecamatan Minas,” *Diklat Rev. J. Manaj. Pendidik. dan Pelatih.*, vol. 6, no. 1, pp. 94–101, 2022, [Online]. Available: <https://ejournal.kompetif.com/index.php/diklatreview/article/view/913>
- [10] M. A. Ramadhan, “Permasalahan Sampah Menjadi Dampak Lingkungan Tidak Sehat,” *J. Kegur. dan Ilmu Pendidik.*, pp. 1–10, 2022.
- [11] K. A. Priana and A. A. I. N. E. Karyawati, “Sistem Pendeteksi Sampah Secara Realtime Menggunakan Metode YOLO,” *J. Nas. Teknol. Inf.*, vol. 2, 2023.
- [12] F. Marpaung, F. Aulia, and R. C. Nabila, *Computer Vision Dan Pengolahan Citra Digital*. Surabaya, Jawa Timur: PUSTAKA AKSARA, 2022. [Online]. Available: www.pustakaaksara.co.id
- [13] N. J. Hayati, D. Singasatia, and M. R. Muttaqin, “Object Tracking Menggunakan Algoritma You Only Look Once (YOLO)v8 untuk Menghitung Kendaraan,” *Komputa J. Ilm. Komput. dan Inform.*, vol. 12, no. 2, pp. 91–99, 2023, doi: 10.34010/komputa.v12i2.10654.
- [14] S. Youwai, A. Chaiphaphat, and P. Chaipetch, “YOLO9tr: a lightweight model for pavement damage detection utilizing a generalized efficient layer aggregation network and attention mechanism,” *J. Real-Time Image Process.*, vol. 21, no. 5, pp. 1–21, 2024, doi: 10.1007/s11554-024-01545-2.
- [15] A. Ramdan et al., “Implementasi Deteksi Objek Real-Time Sebagai Media Edukasi dengan Algoritma YOLOv8 pada Objek Sampah sampah kota , limbah makanan , limbah (Sistem Informasi Pengelolaan Sampah Dengan memanfaatkan Artificial Intelligence , kita dapat menciptakan menurut B,” *SAINTEKOM*, vol. 14, no. 2, pp. 142–153, 2024.
- [16] A. Wang et al., “YOLOv10: Real-Time End-to-End Object Detection,” *Tsinghua Univ.*, pp. 1–18, 2024, [Online]. Available: <http://arxiv.org/abs/2405.14458>
- [17] F. Yusuf Raspati, K. Meta, 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.
- [18] O. Soerya, N. Utomo, F. Utamingrum, and E. R. Widasari, “Implementasi YOLO versi 3 untuk Mengidentifikasi dan Mengklasifikasi Sampah Kantor berbasis NVIDIA Jetson Nano,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 6, pp. 2829–2834, 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [19] R. Theofilus, Rizky and Kurniawan, “Deteksi Sampah di Permukaan Sungai menggunakan Convolutional Neural Network dengan Algoritma YOLOv8,” *Semin. Nas. Off. Stat.*, pp. 537–548, 2024, doi: 10.34123/semnasoffstat.v2024i1.2099.
- [20] U. Ramadhan, N. Santoso, and F. Gamar, “Deteksi Sampah Botol Plastik di Perairan Menggunakan YOLO v4- Tiny,” *J. Teknol. Dan Sist. Inf. Bisnis*, vol. 7, no. 1, pp. 91–98, 2025.
- [21] F. Ciaglia, F. S. Zuppichini, P. Guerrie, M. McQuade, and J. Solawetz, “Roboflow 100: A Rich, Multi-Domain Object Detection Benchmark,” 2022, [Online]. Available: <http://arxiv.org/abs/2211.13523>
- [22] J. Fan, L. Cui, and S. Fei, “Waste Detection System Based on Data Augmentation and YOLO_EC,” *Sensors*, vol. 23, no. 7, 2023, doi: 10.3390/s23073646.
- [23] N. T. S. Saptadi, A. Suyuti, A. A. Ilham, and I. Nurtanio, “Modeling of Organic Waste Classification as Raw Materials for Briquettes using Machine Learning Approach,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 3, pp. 577–585, 2023, doi: 10.14569/IJACSA.2023.0140367.
- [24] E. H. Sanchez, “Read, look and detect: Bounding box annotation from image-caption pairs,” *IRT Saint Exupéry*, no. VI, 2023, [Online]. Available: <http://arxiv.org/abs/2306.06149>
- [25] M. Yaseen, “What is YOLOv8: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector,” 2024, [Online]. Available: <http://arxiv.org/abs/2408.15857>
- [26] C.-Y. Wang, I.-H. Yeh, and H.-Y. M. Liao, “YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information,” *Tsinghua Univ.*, 2024, doi: 10.1007/978-3-031-72751-1_1.
- [27] J. Terven, D. M. Cordova-Esparza, A. Ramirez-Pedraza, E. A. Chavez-Urbiola, and J. A. Romero-Gonzalez, “Loss Functions and Metrics in Deep Learning,” pp. 1–53, 2023, [Online]. Available: <http://arxiv.org/abs/2307.02694>
- [28] J. Zophie and H. H. Triharminto, “Implementasi Algoritma You Only Look Once (YOLO) menggunakan Web Camera untuk Mendeteksi Objek Statis dan Dinamis Implementation of You Only Look Once (YOLO) Algorithm using Web Camera for Static dan Dinamic Object Detection,” *J. TNI Angkatan Udar.*, vol. 1, no. 1, pp. 98–109, 2020.