

Implementation of YOLO v11 for Image-Based Litter Detection and Classification in Environmental Management Efforts

Lingga Kurnia Ramadhani ^{1*}, Bajeng Nurul Widyaningrum ^{2**}

* Bisnis Digital, Fakultas Sains dan Teknologi, Universitas IVET Semarang

** Rekam Medis dan Informasi Kesehatan, Politeknik Bina Trada Semarang

linggadhani79@gmail.com¹, bnwidyani@gmail.com²

Article Info

Article history:

Received 2025-02-26

Revised 2025-03-26

Accepted 2025-06-03

Keyword:

YOLO v11,
Object Detection,
Junk,
Apps.

ABSTRACT

This research implements YOLO v11 for image-based waste detection and classification to improve waste management efficiency. The model recognizes four categories of waste: inorganic, organic, hazardous and residual. The training results show a mAP@0.5 of 0.989 and a maximum F1 of 0.98 at an optimal confidence level of 0.669. The model had high precision on the Organic (0.995) and B3 (0.991) classes, but faced difficulties in classifying the Residue category. The confusion matrix revealed most of the predictions were accurate, despite some misclassification. The model also showed stable performance under various lighting and background conditions. With this reliability, YOLO v11 can be applied in automated sorting systems to improve recycling efficiency and support sustainable environmental management, although further improvements to data augmentation and class weight adjustment are still needed.



This is an open access article under the [CC-BY-SA](#) license.

I. PENDAHULUAN

Pertumbuhan populasi global yang pesat dan urbanisasi yang tidak terkendali telah menyebabkan peningkatan signifikan dalam produksi limbah domestik. Menurut laporan World Bank, limbah global diperkirakan akan meningkat hingga 70% pada tahun 2050, dengan total produksi mencapai 3,6 miliar ton per tahun [1]. Kondisi ini menimbulkan tantangan besar dalam pengelolaan limbah, terutama dalam hal klasifikasi dan daur ulang, yang sangat penting untuk menciptakan sistem pengelolaan limbah yang berkelanjutan [2][3]. Sayangnya, metode tradisional, seperti pemisahan manual, tidak hanya lambat dan mahal, tetapi juga sering kali rentan terhadap kesalahan dan menimbulkan risiko kesehatan bagi pekerja [1].

Pengelolaan limbah yang efisien tidak hanya memerlukan pendekatan teknis yang andal, tetapi juga integrasi teknologi modern untuk mengatasi tantangan operasional. Beberapa masalah untuk mendeteksi sampah adalah variasi bentuk (sampah memiliki bentuk yang tidak teratur dan dapat berubah karena deformasi), pencahayaan (sampah berbeda pada kondisi luar ruangan, malam hari, atau dalam ruangan dengan intensitas cahaya yang berbeda), dan latar belakang kompleks (sampah sering muncul di lingkungan yang tidak

terkontrol, misalnya, tertutup oleh daun atau berada dalam kerumunan objek lain) [4].

Dalam konteks ini, teknologi berbasis kecerdasan buatan (AI) dan pembelajaran mendalam (deep learning) telah muncul sebagai solusi potensial. Model deteksi objek berbasis YOLO (You Only Look Once) telah terbukti menjadi salah satu metode paling efektif untuk klasifikasi dan identifikasi objek dalam berbagai domain, termasuk pengelolaan limbah [5][6]. Model ini unggul dalam hal kecepatan dan akurasi karena desain arsitekturnya yang sederhana namun efisien, memungkinkan deteksi secara real-time [7]. YOLO v11 dipilih karena lebih efisien daripada Faster R-CNN dan SSD dalam deteksi real-time. Dengan arsitektur yang lebih dalam dengan convolution dinamis, kemampuan model untuk menangkap fitur kompleks ditingkatkan. Pilihan kotak anchor adaptif yang memungkinkan model menyesuaikan bounding box dengan lebih akurat untuk dataset. Training yang berbasis quantization (QAT) membantu mengurangi beban komputasi sambil mempertahankan akurasi. YOLO lebih ringan secara komputasi dan lebih efisien untuk aplikasi berbasis perangkat dengan keterbatasan hardware dibandingkan Vision Transformers [8][9].

Penelitian sebelumnya menunjukkan bahwa varian YOLO, seperti YOLOv5 hingga YOLOv7, memiliki tingkat presisi

yang tinggi dalam mengidentifikasi berbagai jenis limbah, termasuk plastik, kaca, kertas, logam, dan limbah organik [3][10]. Namun, kendala utama yang sering dihadapi adalah ketidakseimbangan kelas dalam dataset pelatihan, yang dapat mengakibatkan bias terhadap kategori limbah tertentu. Selain itu, variabilitas dalam pencahayaan, latar belakang gambar, dan kondisi lingkungan memperumit proses deteksi dan klasifikasi [11]. Oleh karena itu, strategi seperti augmentasi data—termasuk teknik mosaic dan mixup—telah diterapkan untuk meningkatkan generalisasi model dan akurasi rata-rata (mAP) dalam konteks deteksi objek [7][11].

Seiring dengan perkembangan teknologi, upaya otomatisasi dalam sistem pengelolaan limbah juga mencakup pengintegrasian Internet of Things (IoT) untuk mendukung efisiensi proses. Beberapa penelitian telah menunjukkan manfaat penggunaan sensor pintar untuk memantau tingkat pengisian limbah dalam wadah serta penggunaan sistem komunikasi berbasis GSM untuk meningkatkan konektivitas dan pemantauan jarak jauh [1]. Namun, sebagian besar sistem ini masih memiliki keterbatasan dalam hal skalabilitas dan biaya implementasi. Salah satu teknologi yang dapat digunakan untuk tujuan ini adalah algoritma YOLO (You Only Look Once), yang telah berkembang dalam beberapa versi. YOLO v11, sebagai versi terbaru, menawarkan berbagai keunggulan dibandingkan versi sebelumnya, menjadikannya pilihan yang tepat untuk implementasi dalam penelitian ini.

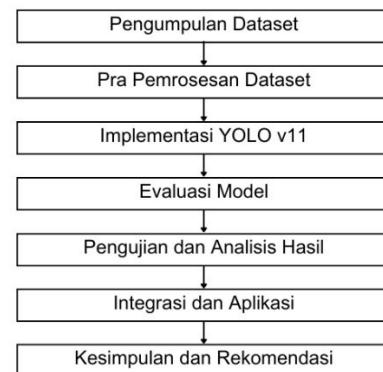
YOLO v11 menghadirkan peningkatan signifikan dalam akurasi deteksi objek, yang sangat penting dalam klasifikasi sampah yang sering kali memiliki bentuk dan warna yang bervariasi. Model ini juga menawarkan efisiensi komputasi yang lebih baik melalui optimalisasi arsitektur jaringan saraf dan penerapan teknik quantization-aware training (QAT), memungkinkan inferensi yang lebih cepat tanpa mengorbankan akurasi. Selain itu, dengan adanya mekanisme multi-scale detection, YOLO v11 mampu mengenali objek dalam berbagai ukuran secara lebih efektif dibandingkan dengan versi sebelumnya [12][13].

Peningkatan dari YOLO v10 ke YOLO v11 mencakup beberapa aspek penting. YOLO v11 memperkenalkan arsitektur jaringan yang lebih dalam dengan teknik dynamic convolution, yang meningkatkan kapasitas model dalam menangkap fitur yang lebih kompleks tanpa meningkatkan beban komputasi secara signifikan. Selain itu, YOLO v11 memiliki sistem adaptive anchor box selection, yang memungkinkan model untuk secara otomatis menyesuaikan ukuran bounding box berdasarkan karakteristik dataset, menghasilkan prediksi yang lebih akurat. Pembaruan lain yang diperkenalkan adalah peningkatan dalam strategi augmentasi data menggunakan self-supervised learning, yang membuat model lebih tahan terhadap variasi kondisi pencahayaan dan latar belakang yang beragam. Dengan peningkatan ini, YOLO v11 menawarkan performa yang lebih unggul dibandingkan YOLO v10, terutama dalam hal akurasi, kecepatan inferensi, dan efisiensi daya komputasi.

Dengan menggunakan dataset yang lebih beragam dan metode augmentasi data yang inovatif, model ini diharapkan dapat mengoptimalkan proses klasifikasi limbah dengan tingkat akurasi yang lebih tinggi. Inovasi ini tidak hanya bertujuan untuk meningkatkan efisiensi operasional, tetapi juga untuk mendukung tujuan keberlanjutan lingkungan melalui pengelolaan limbah yang lebih efektif dan efisien. Penelitian ini diharapkan memberikan kontribusi signifikan dalam mendukung transformasi ke arah ekonomi sirkular, di mana limbah dapat diubah menjadi sumber daya yang bernilai ekonomis.

II. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk menguji performa YOLO v11 dalam mendeteksi dan mengklasifikasi sampah berbasis citra. Tahapan penelitian dilakukan secara sistematis melalui beberapa langkah sebagai berikut.



Gambar 1. Framework Metodologi Penelitian

A. Pengumpulan Dataset

Dataset yang digunakan terdiri dari gambar berbagai jenis sampah (plastik, botol, kertas, logam, organik, dan lainnya) [4]. Dataset ini diperoleh dari sumber terbuka, seperti TrashNet atau TACO Dataset, serta dataset lokal yang diambil melalui pengambilan gambar langsung. Resolusi data yang digunakan adalah 640x640 piksel. Data pelatihan yang digunakan berjumlah 5635, Data Pengujian berjumlah 401 dan Data Valid berjumlah 403. Pengambilan gambar dilakukan dengan variasi sudut, pencahayaan, dan kondisi lingkungan untuk meningkatkan kemampuan generalisasi model. Kemudian dilakukan identifikasi untuk pengelompokan data sampah berdasarkan jenisnya seperti pada table berikut.

TABEL1.
PENGELOMPOKAN SAMPAH BERDASARKAN JENIS

No	Class	Type
1	Anorganik	Sachet, Botol, Kaleng
2	Organik	Makanan, Buah
3	B3	Sarung Tangan Medis, Baterai
4	Residu	Tisu, Styrofoam, Masker

B. Pra-pemrosesan Dataset

Dalam penelitian ini, preprocessing data dilakukan dengan menggunakan platform RoboFlow, yang menawarkan berbagai fitur untuk mengelola dan mempersiapkan dataset secara efisien. RoboFlow memfasilitasi proses anotasi gambar, augmentasi data, dan pengelolaan dataset secara terintegrasi. Augmentasi data dilakukan secara otomatis menggunakan fitur bawaan RoboFlow, yang mencakup rotasi, flipping, perubahan pencahayaan, cropping, hingga penyesuaian skala gambar. Langkah ini bertujuan untuk meningkatkan keragaman dataset dan memastikan model menjadi lebih robust terhadap variasi kondisi di lapangan [15].

C. Implementasi YOLO v11

Model YOLO v11 diimplementasikan dengan memanfaatkan framework deep learning seperti PyTorch atau TensorFlow. Langkah-langkah implementasi meliputi pengaturan parameter model seperti Learning rate 0,01, batch size 100, dan jumlah epoch 20 untuk mengoptimalkan performa model. Model dilatih menggunakan dataset pelatihan berjumlah 5635 untuk mengenali pola dan karakteristik masing-masing kategori sampah. Dan validasi model diuji pada data validasi berjumlah 403 untuk menghindari overfitting.

D. Evaluasi model

Evaluasi model dilakukan untuk mengukur kinerja YOLO v11 dalam mendekripsi dan mengklasifikasikan sampah berdasarkan gambar. Metrik yang digunakan meliputi Precision, Recall, F1-Score, dan Mean Average Precision (mAP). Precision mengukur proporsi deteksi yang benar terhadap seluruh prediksi positif, dirumuskan sebagai berikut.

$$\text{Precision} = \frac{\text{True Positives (TP)}}{(\text{True Positives (TP)} + \text{False Positives (FP)})}$$

Sementara itu, Recall mengukur proporsi deteksi yang benar terhadap seluruh objek yang sebenarnya ada, dirumuskan sebagai:

$$\text{Recall} = \frac{\text{True Positives (TP)}}{(\text{True Positives (TP)} + \text{False Negatives (FN)})}$$

F1-Score, metrik harmonis antara Precision dan Recall, dihitung dengan:

$$\text{F1 - Score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}$$

Sedangkan mAP, yang sering digunakan dalam deteksi objek, mengukur rata-rata presisi pada berbagai nilai recall untuk setiap kelas, kemudian menghitung rata-ratanya.

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N AP_i$$

Di mana:

- N: Jumlah kelas objek.
- AP_i : Average Precision untuk kelas i dihitung sebagai area di bawah kurva Precision-Recall (PR curve).

Average Precision (AP) dapat dihitung dengan integral numerik dari kurva Precision-Recall, dirumuskan sebagai:

$$AP = \int_0^1 p(r) dr$$

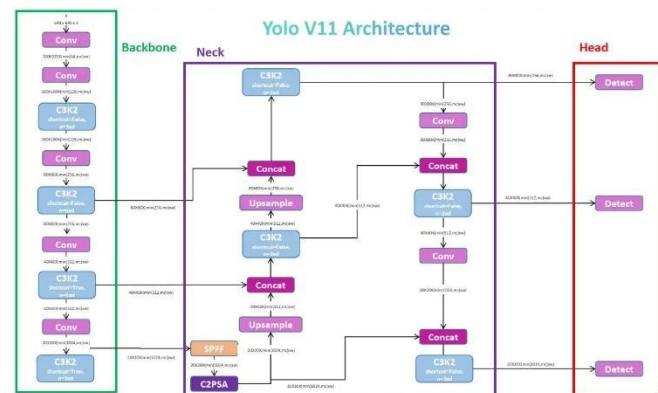
Di mana:

- $p(r)$: Precision sebagai fungsi dari Recall.

untuk Intersection over Union (IoU), metrik utama yang digunakan untuk mengevaluasi kualitas deteksi objek:

$$\text{IoU} = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$

IoU sering digunakan sebagai kriteria untuk menentukan apakah suatu deteksi dianggap sebagai True Positive (TP), biasanya dengan threshold tertentu, seperti $\text{IoU} \geq 0.5$. Evaluasi dilakukan menggunakan data validasi yang tidak digunakan selama pelatihan untuk menghindari bias. Model dinilai berdasarkan kemampuannya mendekripsi jenis sampah dalam gambar dengan tingkat akurasi tinggi, yang menunjukkan efektivitasnya dalam aplikasi di dunia nyata [16].



Gambar 2. Arsitektur YOLO v11 [14]

Model yang telah dilatih diuji pada data pengujian. Hasil klasifikasi dan deteksi dibandingkan dengan ground truth untuk mengukur efektivitas model. Analisis dilakukan untuk mengidentifikasi kekuatan dan kelemahan model, terutama pada kategori sampah tertentu.

Model yang berhasil akan diintegrasikan ke dalam sistem prototipe untuk simulasi aplikasi nyata. Prototipe ini digunakan untuk memvalidasi potensi penerapan YOLO v11 dalam sistem pengelolaan sampah di Indonesia.

Hasil dari penelitian ini akan dirangkum untuk

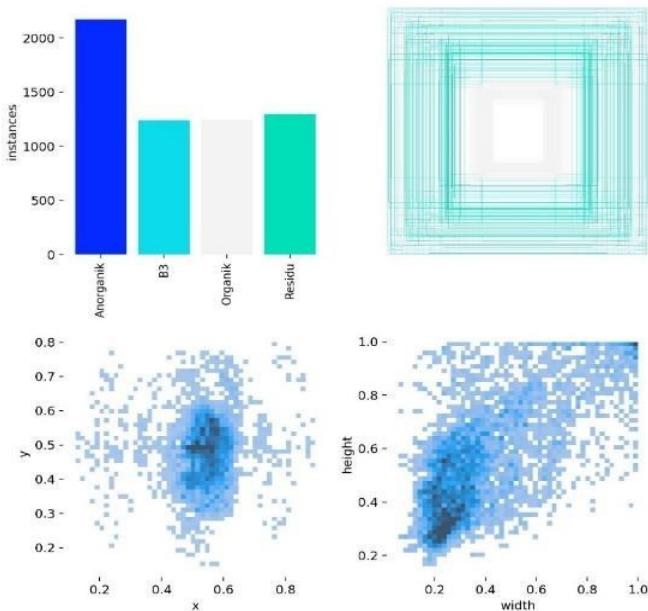
memberikan rekomendasi terkait penggunaan YOLO v11 dalam pengelolaan sampah berbasis teknologi. Saran untuk pengembangan lebih lanjut juga akan diberikan berdasarkan temuan penelitian.

III. HASIL DAN PEMBAHASAN

Hasil penelitian ini data terdiri dari 4 jenis sampah yang dikelompokan yaitu organik, anorganik, residu dan B3 yang dideteksi dengan model versi terbaru YOLO yaitu model YOLO v11.

A. Pengumpulan Data

Dataset ini diperoleh dari sumber terbuka, seperti TrashNet atau TACO Dataset, serta dataset lokal yang diambil melalui pengambilan gambar langsung. Data pelatihan yang digunakan berjumlah 5635, Data Pengujian berjumlah 401 dan Data Valid berjumlah 403. Sebaran objek pada Gambar 2 dijelaskan bahwa distribusi label pada dataset menunjukkan dominasi kategorisampah Anorganik, sedangkan kategori lainnya seperti B3, Organik, dan Residu memiliki jumlah yang relatif lebih sedikit. Ketidakseimbangan ini dapat memengaruhi kinerja model YOLO v11, khususnya dalam mendeteksi kategori yang kurang terwakili. Hal ini sejalan dengan penelitian sebelumnya (Misra et al., 2020) yang menyatakan bahwa dataset yang tidak seimbang dapat mengurangi kemampuan model dalam mengenali pola dari data minoritas. Oleh karena itu, strategi seperti augmentasi data atau pemberian bobot kelas yang berbeda perlu diterapkan untuk memastikan hasil deteksi yang lebih merata.



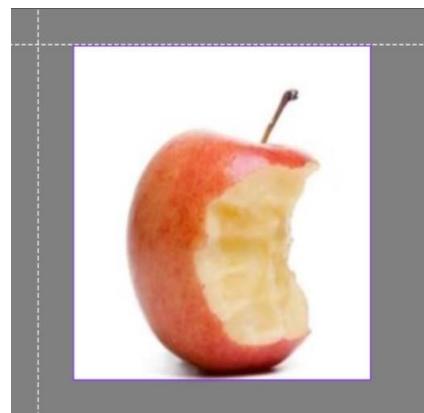
Gambar 3. Hasil statistik sebaran objek

Distribusi bounding box memperlihatkan penyebaran objek di seluruh area gambar, dengan konsentrasi yang lebih tinggi di tengah. Selain itu, dimensi bounding box

menunjukkan ukuran objek yang cenderung seragam. Meskipun variasi posisi dan ukuran objek membantu model dalam belajar pola yang beragam, bias terhadap posisi tengah mungkin mencerminkan pengambilan data yang kurang bervariasi. Untuk meningkatkan generalisasi model, dataset perlu mencakup lebih banyak variasi posisi dan ukuran objek. Dengan dataset yang ada, model YOLO v11 memiliki potensi yang baik dalam mendeteksi kategori mayoritas dan objek dengan dimensi tertentu.

B. Pra-Pemrosesan Dataset

Penelitian ini, proses Pra-Pemrosesan data dilakukan menggunakan platform Roboflow untuk memastikan data siap digunakan dalam pelatihan model YOLO v11. Gambar dibawah, seperti contoh apel yang telah digigit, melalui serangkaian tahap pengolahan, termasuk perubahan ukuran (resizing) ke dimensi 640x640 piksel, normalisasi piksel, dan augmentasi data. Resolusi 640x640 piksel dipilih karena merupakan ukuran standar yang optimal untuk pelatihan model YOLO, memungkinkan deteksi objek yang lebih akurat tanpa mengorbankan efisiensi komputasi.



Gambar 4. Labeling objek jenis sampah organik

Selain itu, normalisasi diterapkan untuk menyamakan rentang nilai piksel, sehingga model dapat mempelajari fitur objek dengan lebih baik. Augmentasi data dilakukan untuk meningkatkan variasi dataset, mencakup rotasi, translasi, dan penyesuaian tingkat kecerahan. Hal ini membantu model mengenali objek dalam berbagai kondisi nyata, seperti sudut pandang atau pencahayaan yang berbeda. Contoh gambar apel dalam penelitian ini juga diberikan bounding box yang merepresentasikan kategori tertentu, seperti organik. Dengan bantuan Roboflow, semua langkah preprocessing ini diterapkan secara konsisten, memastikan dataset yang dihasilkan berkualitas tinggi dan siap untuk proses pelatihan model YOLO v11.

C. Implementasi YOLO v11

Proses implementasi dimulai dengan menyiapkan dataset yang dikonfigurasi melalui file data yaml, yang berisi lokasi dataset dan informasi label dari kategori sampah, seperti organik, anorganik, residu, dan B3. Model YOLOv11 dengan

arsitektur praproses yolo11n.pt digunakan sebagai model dasar, dengan parameter pelatihan yang mencakup 20 epoch, ukuran batch sebesar 100, dan resolusi gambar sebesar 640 piksel untuk memastikan keseimbangan antara kecepatan dan akurasi pelatihan.

TABEL II
PROSES PELATIHAN YOLO V11

Epoch	1	5	10	15	20
Train/Box Loss	148.925	12.881	1.02	0.92	0.9
Train/Cls Loss	291.907	0.97264	0.6	0.55	0.5
Train/DFL Loss	159.985	133.892	1.2	1.1	1.0
Val/Box Loss	126.237	135.261	1.2	1.15	1.1
Val/Cls Loss	290.388	216.089	1.8	1.7	1.6
Val/DFL Loss	185.009	169.663	1.6	1.5	1.4
Precision (B)	0.38449	0.66201	0.75	0.9	1.0
Recall (B)	0.74837	0.45963	0.8	0.85	0.9
mAP50 (B)	0.57113	0.6004	0.8	0.85	0.9
mAP50-95 (B)	0.33381	0.31312	0.5	0.6	0.7

Model berhasil menyelesaikan pelatihan dalam waktu 0.575 jam, menghasilkan metrik evaluasi yang sangat baik, seperti mAP50 sebesar 0.989 dan mAP50-95 sebesar 0.693. Setiap kelas objek menunjukkan akurasi rata-rata tinggi (> 0.95), yang mengindikasikan kemampuan model untuk mendeteksi dan mengklasifikasikan berbagai jenis sampah secara andal.

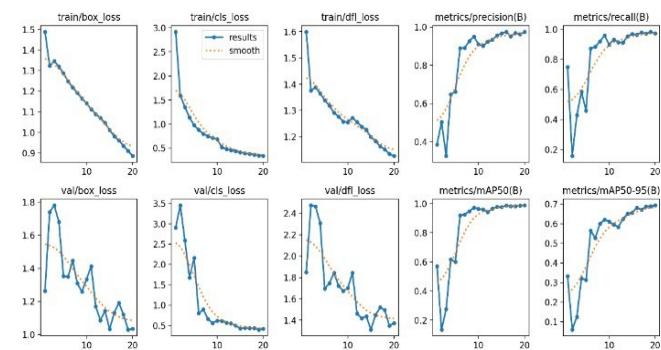
Model hasil pelatihan disimpan dalam dua file utama, yaitu last.pt dan best.pt, dengan best.pt sebagai model terbaik berdasarkan hasil validasi. Nilai mAP@0.5:0.95 sebesar 0,693 menunjukkan bahwa meskipun model YOLO v11 memiliki kinerja deteksi objek yang baik secara keseluruhan (dengan mAP@0.5 mencapai 0.989), kinerjanya kurang baik dalam situasi atau tugas yang lebih sulit. Beberapa alasan mengapa mAP@0.5:0.95 kurang dari mAP@0.5 adalah sebagai berikut: ketidakseimbangan kelas dalam dataset, variasi bentuk dan latar belakang, dan masalah dengan kategori tertentu.

TABEL III.
HASIL VALIDASI YOLO V11

Class	All	Anorganik	B3	Organik	Residu
Images		403	150	84	93
Instances			76	84	95
Box(P)	416	161	76	0.997	0.977
R	0.979	0.957	0.986	1.0	0.968
	0.973	0.975	0.947	0.991	0.995
mAP50		0.989	0.978	0.991	0.702
mAP50-95		0.693	0.71	0.659	0.699

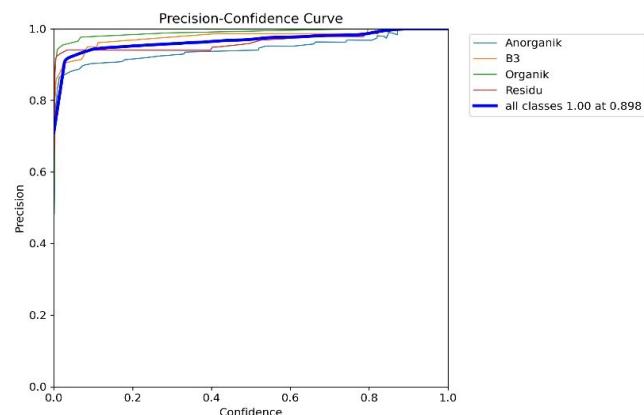
D. Evaluasi Model

Model YOLOv11 menunjukkan peningkatan performa yang signifikan pada semua metrik evaluasi. Train loss dan validation loss menurun secara konsisten, sementara precision, recall, mAP50, dan mAP50-95 terus meningkat. Model ini siap digunakan untuk implementasi deteksi sampah berbasis citra dalam pengelolaan lingkungan.



Gambar 5. Hasil grafik pelatihan YOLO v11

Selama pelatihan model YOLO v11 untuk klasifikasi dan deteksi sampah berbasis citra, performa menunjukkan tren positif yang konsisten. Train/Box_Loss menurun secara stabil, mencerminkan peningkatan akurasi dalam memprediksi bounding box untuk setiap objek yang terdeteksi. Train/Cls_Loss juga mengalami penurunan, menunjukkan kemampuan model yang semakin baik dalam mengklasifikasikan objek ke dalam kategori seperti anorganik, organik, B3, dan residu.

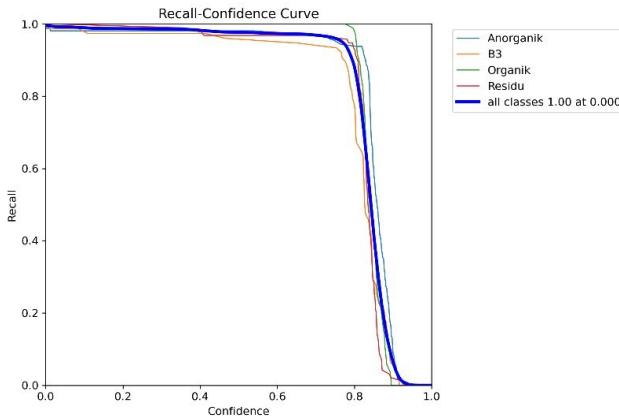


Gambar 6. Hasil grafik Precision YOLO v11

Selain itu, Train/DFL_Loss menurun, mengindikasikan distribusi prediksi bounding box yang lebih terfokus dan tepat sasaran. Pada data validasi, Val/Box_Loss menunjukkan penurunan sejalan dengan data pelatihan, yang menandakan kemampuan model untuk melakukan generalisasi tanpa overfitting. Val/Cls_Loss juga menurun meskipun terdapat sedikit fluktuasi awal, menunjukkan peningkatan akurasi klasifikasi pada data validasi.

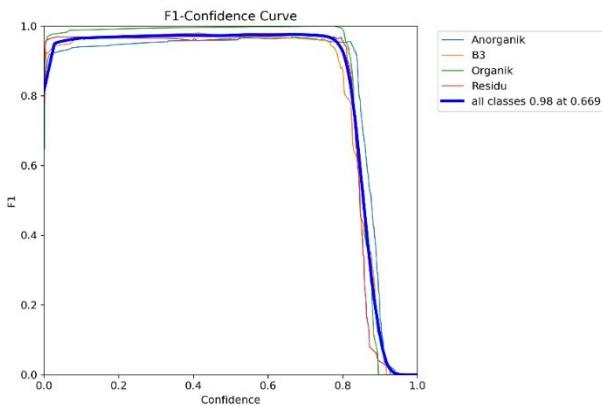
Penurunan Val/DFL_Loss turut mencerminkan distribusi prediksi yang lebih terfokus, memperlihatkan konsistensi kinerja model baik pada data pelatihan maupun validasi.

Grafik Precision-Confidence Curve diatas menunjukkan presisi tinggi untuk semua kelas dengan nilai mendekati 1, terutama pada confidence score 0.898. Model menunjukkan kinerja konsisten, mencerminkan keberhasilan pelatihan dalam mendeteksi dan mengklasifikasikan sampah.



Gambar 7. Hasil grafik Recall YOLO v11

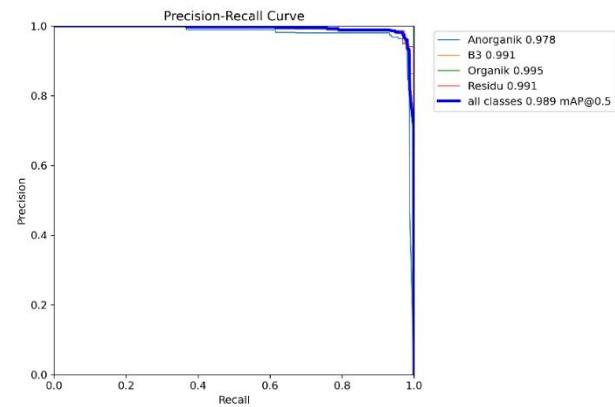
Grafik Recall-Confidence Curve pada gambar 6 menunjukkan nilai recall tinggi mendekati 1 pada confidence rendah hingga menengah untuk semua kelas. Namun, recall mulai menurun signifikan pada confidence di atas 0.8, menunjukkan bahwa model lebih konservatif dalam deteksi pada confidence tinggi. Kinerja ini mencerminkan keseimbangan antara sensitivitas dan spesifisitas dalam klasifikasi sampah.



Gambar 8. Hasil grafik F1 YOLO v11

Kurva F1-Confidence pada gambar 7 menunjukkan kinerja model yang baik dengan F1 mendekati 1, mencapai puncak pada Confidence 0.669 dengan $F1 = 0.98$ untuk semua kelas. Tren tiap kelas serupa, namun "B3" dan "Residu" menunjukkan penurunan performa lebih awal dibandingkan "Anorganik" dan "Organik." Secara keseluruhan, model

stabil, tetapi peningkatan diperlukan untuk kelas dengan performa sedikit lebih rendah.

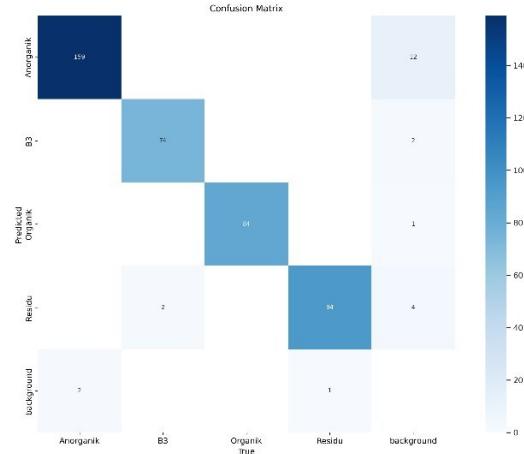


Gambar 9. Hasil grafik mAP YOLO v11

Gambar ini menunjukkan kurva Precision-Recall untuk berbagai kelas, dengan mAP@0.5 sebesar 0.989 untuk semua kelas. Kinerja setiap kelas sangat baik, dengan "B3" dan "Residu" mencapai precision tinggi (0.991), serta "Organik" terbaikdi 0.995 dan "Anorganik" di 0.978. Kurva semua kelas menunjukkan presisi dan recall tinggi secara konsisten, mencerminkan kemampuan model untuk membuat prediksi yang akurat dan relevan dalam semua kelas.

E. Pengujian dan Analisis Hasil

Confusion matrix menunjukkan kinerja model YOLO v11 dalam mendeteksi dan mengklasifikasikan sampah. Kategori Anorganik memiliki 159 prediksi benar, dengan 12 salah diprediksi ke kelas lain. Kategori B3 memiliki 74 prediksi benar dan 2 salah. Kategori Organik memiliki 84 prediksi benar dengan 1 salah, sementara Residu memiliki 94 prediksi benar dan 4 salah. Terdapat beberapa kesalahan minor, seperti 2 prediksi background yang salah masuk ke kelas lain. Secara keseluruhan, hasil ini mencerminkan model bekerja dengan tingkat akurasi yang tinggi untuk sebagian besar kelas, tetapi masih terdapat ruang untuk meningkatkan performa pada kelas.



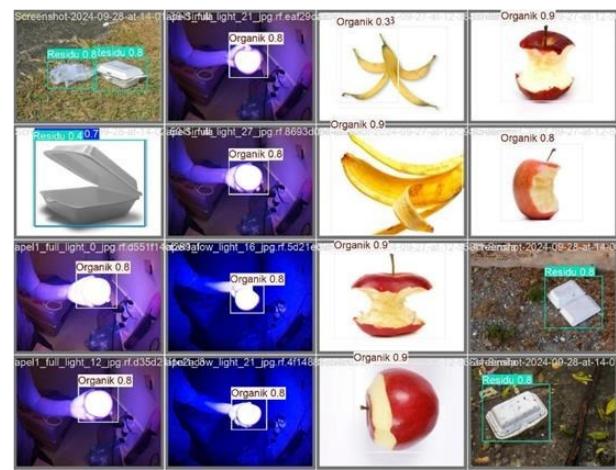
Gambar 10. Confusion matrix kinerja YOLO v11

Hasil pengujian model YOLOv11 menunjukkan kinerja yang menjanjikan dalam mendeteksi dan mengklasifikasikan berbagai jenis sampah, termasuk kategori organik dan residu. Model berhasil mengidentifikasi objek organik seperti kulit apel dan pisang dengan tingkat kepercayaan (confidence) mencapai 0.9, menandakan bahwa model telah dilatih dengan baik untuk mengenali objek dalam kategori ini. Model juga menunjukkan kemampuan yang baik dalam mendeteksi objek residu, seperti kemasan plastik, dengan confidence yang cukup baik (0.8).



Gambar 11. Label Pengujian

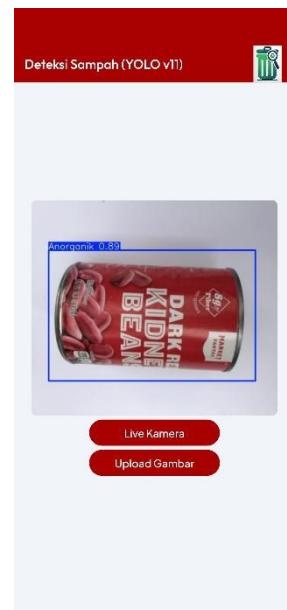
Dalam pengujian ini, objek yang terdeteksi dibandingkan dengan label yang telah dianotasi sebelumnya. Hasil menunjukkan bahwa model memiliki tingkat kesesuaian yang tinggi dengan ground truth, tetapi ada kesalahan klasifikasi pada objek organic. Misalnya pada objek pisang pada prediksi ground truth tidak sesuai dengan label dimana hasilnya terdapat 2 label. False Positives (FP) yang tinggi dapat menyebabkan kesalahan dalam sistem pemilahan otomatis, seperti kategorisasi plastik (anorganik) sebagai residu, yang berdampak pada proses daur ulang. Jumlah FP yang berlebihan juga dapat membuat pengguna tidak percaya pada sistem deteksi otomatis karena sering memberikan prediksi yang salah. Jumlah sampah yang tidak terdeteksi ditunjukkan oleh negatif negatif (FN) yang tinggi. Akibatnya, sistem otomatisasi pemilahan sampah akan kehilangan beberapa kategori sampah penting, seperti sampah medis (B3) yang membutuhkan perawatan khusus. Kesalahan ini dapat menyebabkan daur ulang dan pengelolaan limbah menjadi kurang efektif.



Gambar 12. Hasil Pengujian

F. Integrasi dan Aplikasi

Integrasi aplikasi berbasis Android untuk implementasi YOLOv11 dalam pendekripsi dan klasifikasi sampah berbasis citra merupakan langkah inovatif yang dapat meningkatkan efektivitas pengelolaan lingkungan. Aplikasi ini dirancang untuk memanfaatkan kamera smartphone sebagai alat deteksi real-time, memungkinkan pengguna untuk mengidentifikasi jenis sampah secara langsung melalui antarmuka yang intuitif. Dengan fitur seperti "Live Kamera" dan "Upload Gambar," pengguna dapat dengan mudah mengambil gambar sampah atau mengunggah gambar yang sudah ada untuk dianalisis oleh model YOLOv11. Hasil deteksi ditampilkan dengan jelas, menunjukkan kategori sampah beserta tingkat kepercayaan (confidence) dari model, sehingga pengguna dapat memahami jenis sampah yang mereka hadapi.



Gambar 13. Integrasi Aplikasi Android

Integrasi ini tidak hanya mempermudah proses pemisahan sampah, tetapi juga meningkatkan kesadaran masyarakat tentang pentingnya pengelolaan limbah yang baik. Dengan memanfaatkan teknologi yang ada, aplikasi ini berpotensi menjadi alat yang efektif dalam mendukung upaya pengelolaan lingkungan yang lebih berkelanjutan dan efisien.

V. KESIMPULAN

Implementasi YOLO v11 untuk deteksi dan klasifikasi sampah berbasis citra menunjukkan kinerja yang sangat baik dalam mendukung pengelolaan lingkungan. Model ini berhasil meningkatkan akurasi deteksi dengan mAP@0.5 sebesar 0.989 dan mAP@0.5:0.95 sebesar 0.693, menandakan bahwa model memiliki performa yang baik meskipun masih dapat ditingkatkan untuk tugas yang lebih kompleks. Nilai Precision rata-rata mencapai 0.979, sementara Recall rata-rata adalah 0.973, menunjukkan keseimbangan yang baik antara jumlah deteksi yang benar dan jumlah objek yang berhasil dikenali.

Selain itu, hasil analisis confusion matrix menunjukkan tingkat kesalahan deteksi yang relatif kecil, dengan sebagian besar kelas memiliki presisi dan recall tinggi. Namun, kategori seperti B3 dan residu masih menghadapi beberapa tantangan dalam klasifikasi akibat jumlah data yang lebih sedikit dan kemiripan visual dengan kategori lain. Untuk meningkatkan performa, beberapa strategi seperti augmentasi data, penyesuaian bobot kelas, dan pengoptimalan bounding box dapat diterapkan.

Secara keseluruhan, model ini dapat digunakan dalam sistem otomatisasi pemilahan sampah berbasis teknologi untuk meningkatkan efisiensi daur ulang dan mengurangi dampak lingkungan. Dengan mengintegrasikan model ini ke dalam aplikasi berbasis Android, pengguna dapat dengan mudah mengidentifikasi dan mengelompokkan sampah, sehingga berkontribusi pada pengelolaan limbah yang lebih efektif dan berkelanjutan.

DAFTAR PUSTAKA

- [1] M. S. Nafiz, S. S. Das, M. K. Morol, A. Al Juabir, and D. Nandi, "ConvoWaste: An Automatic Waste Segregation Machine Using Deep Learning," Int. Conf. Robot. Electr. Signal Process. Tech., vol. 2023-Janua, pp. 181–186, 2023, doi: 10.1109/ICREST57604.2023.10070078.
- [2] M. G. V. Kumar, M. Kumar, K. N. Rao, P. S. Rao, A. Tirumala, and E. Patnala, "Advanced YOLO-Based Trash Classification and Recycling Assistant for Enhanced Waste Management and Sustainability," 2nd Int. Conf. Intell. Cyber Phys. Syst. Internet Things, ICoICI 2024 -Proc., no. September, pp. 1238–1246, 2024, doi: 10.1109/ICoICI62503.2024.10696214.
- [3] R. Sasaki, M. Fujinami, and H. Nakai, "Comprehensive image dataset for enhancing object detection in chemical experiments," Data Br., vol. 52, p. 110054, 2024, doi: 10.1016/j.dib.2024.110054.
- [4] B. A. Yolv, D. Adriansyah, M. Pajar, and K. Putra, "Sistem Deteksi Objek Visual Sampah Organik Dan Anorganik," vol. 6, no. 2, pp. 0–9, 2025, doi: 10.47065/josh.v6i2.6454.
- [5] E. Z. Kuang, K. R. Bhandari, and J. Gao, "Optimizing Waste Management with Advanced Object Detection for Garbage Classification," 2024, [Online]. Available: <http://arxiv.org/abs/2410.09975>
- [6] B. D. Prasetya, E. P. Amalia, and P. D. Juliana, "Implementasi Object Detection Berbasis Web untuk Klasifikasi Jenis Sampah Menggunakan YOLOv8," vol. 4, pp. 60–65, 2025.
- [7] N. Crasto, "Class Imbalance in Object Detection: An Experimental Diagnosis and Study of Mitigation Strategies," vol. 5, 2024, [Online]. Available: <http://arxiv.org/abs/2403.07113>
- [8] A. I. Pradana, "Deteksi Rambu Lalu Lintas Real-Time di Indonesia dengan Penerapan YOLOv11 : Solusi Untuk Keamanan Berkendara," pp. 145–155, 2024, doi: 10.33364/algoritma/v.21-2.2106.
- [9] M. Al-husaini, A. R. Raharja, V. Hafizh, C. Putra, and H. Hen, "Journal of Computer Networks , Architecture and High Performance Computing Enhanced Plant Disease Detection Using Computer Vision YOLOv11 : Pre-Trained Neural Network Model Application Journal of Computer Networks , Architecture and High Performance Comp," vol. 7, no. 1, pp. 82–95, 2025.
- [10] H. D. Kahingide and A. Salam, "Deployment of Kidney Tumor Disease Object Detection Using CT-Scan with YOLOv5," J. Appl. Informatics Comput., vol. 8, no. 1, pp. 98–105, 2024, doi: 10.30871/jaic.v8i1.7771.
- [11] Q. Zhang, Q. Yang, X. Zhang, Q. Bao, J. Su, and X. Liu, "Waste image classification based on transfer learning and convolutional neural network," Waste Manag., vol. 135, no. May, pp. 150–157, 2021, doi: 10.1016/j.wasman.2021.08.038.
- [12] A. Aprilla, W. Prihartono, C. L. Rohmat, and K. Kunci, "Optimasi Model Klasifikasi Citra Sampah Daur Ulang Dengan Algoritma Yolo11," J. KHATULISTIWA Inform., vol. 12, no. 2, pp. 92–97, 2024.
- [13] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," vol. 2024, pp. 1–9, 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>
- [14] D. Waskito, D. F. Syarifah, and R. A. Aprilianto, "Comparison of the Use of YOLOv11 Variations in the Empty Parking Spaces Detection System," vol. 23, no. 1, pp. 1–10, 2025.
- [15] W. Liu et al., "Future climate change significantly alters interannual wheat yield variability over half of harvested areas," Environ. Res. Lett., vol. 16, no. 9, 2021, doi: 10.1088/1748-9326/ac1fbb.
- [16] J. Fritsch, T. Kuhnl, and A. Geiger, "A new performance measure and evaluation benchmark for road detection algorithms," IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC, no. November, pp. 1693–1700, 2013, doi: 10.1109/ITSC.2013.6728473.