



Implementasi Algoritma YOLOv11 untuk Sistem Klasifikasi Kelayakan Setor Sampah Anorganik dalam Pengelolaan Bank Sampah

Fredy Saputro*, Arita Witanti

Fakultas Teknologi Informasi, Program Studi Informatika, Universitas Mercu Buana Yogyakarta, Sleman
Jl. Jembatan Merah No.84C, Soropadan, Condongcatur, Kec. Depok, Kabupaten Sleman,
Daerah Istimewa Yogyakarta, Indonesia

Email: ¹*211110095@student.mercubuana-yogya.ac.id, ²arita@mercubuana-yogya.ac.id

Email Penulis Korespondensi: 211110095@student.mercubuana-yogya.ac.id

Submitted: 02/06/2025; Accepted: 11/07/2025; Published: 11/07/2025

Abstrak—Pengelolaan sampah anorganik di bank sampah menghadapi tantangan dalam proses pemilahan dan evaluasi kualitas yang masih bergantung pada metode manual dengan tingkat subjektivitas tinggi. Bank Sampah 34 Ngasemrejo mengalami permasalahan ketidakpastian warga mengenai standar kelayakan sampah, yang menyebabkan tingginya tingkat penolakan material dan perilaku masyarakat yang belum optimal dalam penyeteroran sampah. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem deteksi kelayakan sampah anorganik secara otomatis sebelum disetorkan ke bank sampah. Penelitian ini mengembangkan sistem deteksi kelayakan sampah anorganik berbasis computer vision menggunakan algoritma You Only Look Once version 11 (YOLOv11) untuk mengklasifikasikan sampah botol plastik, duplex, dan koran berdasarkan kondisi fisik layak dan tidak layak setor. Dataset penelitian terdiri dari 2.800 citra yang dibagi menjadi 70% data training, 20% data validasi, dan 10% data testing. Preprocessing data dilakukan menggunakan platform Roboflow meliputi anotasi, augmentasi, dan resize menjadi 640x640 piksel. Model YOLOv11n dilatih selama 50 epoch dengan hyperparameter yang dioptimalkan. Hasil evaluasi menunjukkan performa yang sangat baik dengan mAP50 sebesar 99,4%, mAP50-95 sebesar 95,8%, tingkat presisi 98,3%, dan recall 98,6%. Pengujian pada data testing menunjukkan bahwa sistem mampu mengklasifikasikan dengan akurat kelayakan sampah anorganik sesuai dengan standar bank sampah. Sistem ini diharapkan dapat membantu warga dalam memilah sampah secara mandiri, meningkatkan efisiensi operasional bank sampah, serta mendukung proses daur ulang yang lebih berkualitas dan berkelanjutan.

Kata Kunci: Bank Sampah; Deep Learning; Deteksi Objek; Deteksi Sampah; YOLOv11

Abstract—Inorganic waste management in waste banks faces challenges in sorting and quality evaluation processes that still rely on manual methods with high levels of subjectivity. Bank Sampah 34 Ngasemrejo experiences problems with community uncertainty regarding waste eligibility standards, causing high material rejection rates and suboptimal community behavior in waste deposit. Therefore, this research aims to develop an automatic inorganic waste eligibility detection system before depositing to waste banks. This research develops an inorganic waste eligibility detection system based on computer vision using the You Only Look Once version 11 (YOLOv11) algorithm to classify plastic bottles, duplex, and newspaper waste based on eligible and ineligible physical conditions for deposit. The research dataset consists of 2,800 images divided into 70% training data, 20% validation data, and 10% testing data. Data preprocessing was performed using the Roboflow platform including annotation, augmentation, and resize to 640x640 pixels. The YOLOv11n model was trained for 50 epochs with optimized hyperparameters. Evaluation results show excellent performance with mAP50 of 99.4%, mAP50-95 of 95.8%, precision rate of 98.3%, and recall of 98.6%. Testing on testing data shows that the system can accurately classify the eligibility of inorganic waste according to waste bank standards. This system is expected to help residents sort waste independently, improve waste bank operational efficiency, and support higher quality and sustainable recycling processes.

Keywords: Waste Bank; Deep Learning; Object Detection; Waste Detection; YOLOv11

1. PENDAHULUAN

Pengelolaan sampah telah menjadi isu global yang semakin kompleks seiring dengan pertumbuhan populasi dan peningkatan tingkat konsumsi masyarakat. Studi terbaru menunjukkan bahwa sampah plastik di seluruh dunia diperkirakan akan meningkat hampir tiga kali lipat pada tahun 2060, dari 353 juta ton pada tahun 2019 menjadi 1.014 juta ton, dengan kurang dari seperlimanya didaur ulang dan sekitar setengahnya dibuang di tempat pembuangan sampah [1]. Di Indonesia, negara kepulauan dengan populasi yang besar, pengelolaan sampah, terutama sampah plastik, adalah masalah besar. Sekitar 58% sampah plastik tidak terkelola secara optimal, sementara proses daur ulang banyak bergantung pada sektor informal yang hanya menangani sebagian kecil dari total produksi sampah [2]. Situasi ini tidak hanya berdampak pada pencemaran lingkungan, tetapi juga berdampak pada keseimbangan ekosistem dan kesehatan masyarakat [3].

Bank sampah sebagai model pengelolaan sampah berbasis masyarakat (community-based waste management) telah berkembang di Indonesia sebagai solusi inovatif untuk mengurangi volume sampah dan memberikan nilai ekonomis kepada masyarakat. Meskipun Indonesia menghasilkan jumlah sampah yang substansial setiap tahunnya, tingkat daur ulang negara ini masih terbatas, yakni kurang dari 25% [4]. Gerakan pengelolaan sampah berbasis masyarakat ini diharapkan dapat mendukung ekonomi sirkular dan ketahanan lingkungan melalui aksi socio-lingkungan yang berkelanjutan [5]. Meski demikian, bank sampah masih mengalami kendala dalam pelaksanaannya, khususnya pada tahapan pemilahan dan evaluasi kualitas sampah anorganik yang bergantung pada metode manual dengan tingkat subjektivitas tinggi. Minimnya pengetahuan dan kesadaran



masyarakat Indonesia tentang pengelolaan sampah yang tepat, khususnya di wilayah pesisir pedesaan, mengakibatkan perlunya implementasi sistem pengelolaan sampah yang lebih efektif [6].

Bank Sampah 34 Ngasemrejo mengalami tantangan yang sama, di mana ketidakpastian warga mengenai standar kelayakan sampah menyebabkan tingginya tingkat penolakan material yang tidak sesuai kriteria. Permasalahan ini diperparah oleh perilaku masyarakat yang belum optimal dalam menyetorkan sampah, baik berupa sampah yang sebenarnya layak setor namun tidak disetorkan, maupun sampah yang tidak memenuhi kriteria namun tetap diserahkan ke bank sampah. Untuk mengatasi permasalahan tersebut, diperlukan pengembangan sistem deteksi kelayakan sampah anorganik berbasis teknologi computer vision yang dapat memberikan penilaian objektif dan konsisten terhadap kondisi fisik sampah sebelum disetor.

Berbagai penelitian telah dilakukan untuk mengembangkan sistem klasifikasi dan deteksi sampah anorganik dengan memanfaatkan algoritma deep learning, khususnya Convolutional Neural Network (CNN) dan YOLO. Triyanto et al. berhasil membangun sistem deteksi real-time untuk botol plastik dan kaleng menggunakan YOLOv8 dengan tingkat akurasi mAP mencapai 99,5% [7]. Dalam konteks serupa, Kirana et al. mengimplementasikan YOLOv6 dan YOLOv7 untuk identifikasi botol plastik yang mengapung di permukaan air, dengan YOLOv6 menunjukkan performa mAP sebesar 0,873 [8]. Beberapa penelitian lain memanfaatkan pendekatan CNN untuk klasifikasi sampah, seperti yang dilakukan Oktafiandi dan Winarnie melalui arsitektur MobileNet yang mampu mengklasifikasikan sampah anorganik dengan tingkat akurasi 93% [9]. Haqqi et al. juga mengembangkan sistem untuk mengklasifikasikan enam kategori sampah berbeda (kaca, kardus, kertas, logam, organik, dan plastik) dengan perolehan akurasi hingga 95% [10]. Sementara itu, Claudia dan Astuti mengintegrasikan CNN ke dalam aplikasi mobile untuk klasifikasi jenis sampah, meskipun dengan hasil akurasi yang relatif lebih rendah yaitu 81,08% [11].

Walaupun penelitian-penelitian tersebut menunjukkan capaian yang signifikan, beberapa kesenjangan penelitian masih perlu dijangkau. Sebagian besar penelitian hanya berfokus pada klasifikasi jenis sampah tanpa mempertimbangkan dimensi kelayakan fisik, seperti keadaan fisik botol apakah kosong, bersih, atau rusak, yang merupakan faktor penting untuk penentuan sampah layak setor. Selain itu, belum ada penelitian yang secara spesifik menggunakan algoritma YOLOv11 untuk deteksi kelayakan sampah anorganik yang disesuaikan dengan karakteristik dan kebutuhan lokal, seperti kondisi yang dihadapi Bank Sampah 34 Ngasemrejo.

Beberapa penelitian terkini menunjukkan perkembangan signifikan dalam deteksi sampah menggunakan deep learning. Li et al. (2024) mengembangkan sistem deteksi sampah padat menggunakan YOLOv8 yang telah dioptimasi dengan lightweight convolutional neural networks, menunjukkan peningkatan efisiensi komputasi namun masih terbatas pada pengenalan jenis tanpa evaluasi kondisi fisik [12]. Kirana et al. (2024) mengimplementasikan pendekatan deep learning untuk deteksi botol plastik pada permukaan air menggunakan YOLOv6 dan YOLOv7, dengan fokus pada deteksi sampah di perairan bukan untuk aplikasi bank sampah [13]. Sementara itu, Chen et al. (2024) mengusulkan deteksi sampah pada permukaan air berbasis lightweight YOLOv5 yang menunjukkan performa baik dalam lingkungan akuatik, namun belum diaplikasikan untuk konteks penilaian kelayakan sampah anorganik [14].

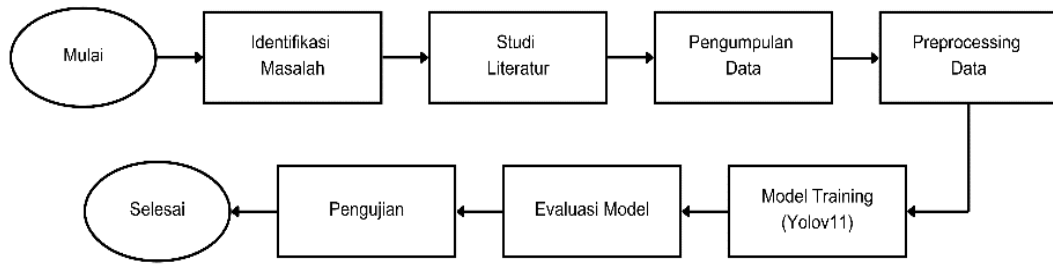
Berdasarkan identifikasi permasalahan, solusi yang ditawarkan, serta analisis terhadap literatur terdahulu, penelitian ini bertujuan untuk mengembangkan sebuah sistem yang dapat mendeteksi kelayakan sampah anorganik secara otomatis sebelum disetorkan ke bank sampah. Sistem ini dirancang dengan menerapkan algoritma YOLOv11, yang merupakan versi terbaru dari keluarga YOLO dengan peningkatan signifikan dalam aspek kecepatan dan presisi deteksi objek secara real-time. Fokus penelitian ini terletak pada tiga jenis sampah anorganik yang umum dijumpai di masyarakat: botol plastik, duplex, dan koran bekas, dengan mekanisme klasifikasi berdasarkan kondisi fisik sampah.

Kontribusi penelitian ini mencakup implementasi algoritma YOLOv11 untuk deteksi kelayakan sampah anorganik berdasarkan kondisi fisik (kebersihan, kekosongan, dan kerusakan), pengembangan dataset khusus untuk tiga jenis sampah anorganik dengan klasifikasi layak/tidak layak setor yang disesuaikan dengan standar bank sampah, evaluasi performa sistem dalam kondisi real-world untuk mendukung efisiensi operasional bank sampah, dan penyediaan solusi teknologi yang dapat membantu masyarakat dalam memilah sampah secara mandiri serta mendukung upaya daur ulang yang lebih berkualitas dan berkelanjutan. Penelitian ini diharapkan dapat membantu warga Bank Sampah 34 Ngasemrejo untuk memilah sampah secara mandiri, meningkatkan efisiensi operasional panitia, serta mendukung upaya daur ulang yang lebih berkualitas dan berkelanjutan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dirancang secara sistematis untuk mengembangkan sistem deteksi sampah anorganik menggunakan model YOLOv11. Gambaran lengkap tahapan penelitian ditunjukkan pada Gambar 1 yang menggambarkan alur kerja penelitian secara keseluruhan.



Gambar 1. Tahapan Penelitian

Berdasarkan Gambar 1, tahapan penelitian dimulai dari identifikasi masalah hingga pengujian model dengan alur yang sistematis dan terstruktur. Setiap tahapan dalam Gambar 1 memiliki keterkaitan logis untuk mencapai tujuan pengembangan sistem deteksi kelayakan sampah anorganik menggunakan YOLOv11. Distribusi dataset yang digunakan dalam penelitian ini dapat dilihat pada Tabel 1 yang menunjukkan pembagian data training, validasi, dan testing.

Tabel 1. Pembagian Data

Jenis Data	Jumlah Data	Rasio
Training	1960	70%
Validasi	560	20%
Pengujian	280	10%
Total	2800	100%

Tabel 1 menunjukkan distribusi dataset yang mengikuti standar pembagian data untuk deep learning dengan rasio 70:20:10 untuk training, validasi, dan testing. Penjelasan setiap tahapan penelitian adalah sebagai berikut:

- a. **Identifikasi Masalah**
Mengidentifikasi masalah ketidakpastian warga mengenai standar kelayakan sampah anorganik di Bank Sampah 34 Ngasemrejo dan kebutuhan sistem deteksi otomatis.
- b. **Studi Literatur**
Mengkaji penelitian terdahulu terkait object detection, YOLOv11, deep learning, dan penerapannya dalam klasifikasi sampah anorganik.
- c. **Pengumpulan Data**
Mengumpulkan dataset 2.800 citra sampah anorganik dari 3 kategori (botol plastik, duplex, koran) dengan pembagian kelas layak dan tidak layak.
- d. **Preprocessing Data**
Mempersiapkan data melalui anotasi, splitting dataset (70:20:10), resize gambar (640x640 piksel), dan augmentasi menggunakan platform Roboflow.
- e. **Model Training YOLOv11**
Melatih model YOLOv11n menggunakan dataset yang telah dipreprocessing dengan implementasi pada Google Colab IDE dan konfigurasi hyperparameter yang optimal.
- f. **Evaluasi Model**
Mengevaluasi performa model menggunakan confusion matrix dan metrik mAP untuk mengukur akurasi deteksi dan klasifikasi dengan threshold IoU 0.5.
- g. **Pengujian**
Menguji model pada data testing untuk menilai kemampuan generalisasi dalam memprediksi kelayakan sampah anorganik dan menganalisis hasil deteksi secara kualitatif dan kuantitatif.

Penerapan metode YOLOv11 dalam menyelesaikan masalah deteksi kelayakan sampah anorganik dilakukan melalui pendekatan end-to-end learning yang mengintegrasikan proses deteksi objek dan klasifikasi kelayakan dalam satu model. Tahapan penerapan dimulai dengan preprocessing dataset menggunakan Roboflow untuk anotasi dan augmentasi data, dilanjutkan dengan konfigurasi model YOLOv11n yang disesuaikan untuk 6 kelas output (botol plastik layak/tidak layak, duplex layak/tidak layak, koran layak/tidak layak). Model dilatih menggunakan transfer learning dengan pre-trained weights dari COCO dataset dan fine-tuning pada dataset sampah anorganik lokal untuk meningkatkan akurasi deteksi sesuai karakteristik sampah di Bank Sampah 34 Ngasemrejo.

2.2 Bank Sampah

Bank sampah merupakan sistem pengelolaan sampah berbasis masyarakat yang mengintegrasikan prinsip 4R (reduce, reuse, recycle, replace) dengan partisipasi aktif warga sebagai modal sosial dalam pengelolaan sampah berkelanjutan [15]. Penerapan sistem bank sampah telah terbukti efektif dalam meningkatkan kesadaran masyarakat terhadap pengelolaan sampah dari sumbernya dan memberikan dampak ekonomi positif bagi komunitas dengan menciptakan sistem ekonomi sirkular di tingkat lokal [16]. Keberhasilan operasional bank

sampah sangat bergantung pada kemampuan mengklasifikasikan sampah berdasarkan jenis dan kelayakannya untuk proses daur ulang yang optimal dan berkelanjutan [17].

2.3 Deep Learning

Deep learning merupakan subset dari machine learning yang menggunakan artificial neural network dengan multiple hidden layers untuk pembelajaran representasi fitur secara hierarkis dan otomatis [18]. Teknologi deep learning telah mengalami perkembangan signifikan dalam dekade terakhir, khususnya dalam aplikasi computer vision dengan kemampuan mencapai performa yang melampaui metode konvensional [19]. Kemampuan deep learning dalam mengenali pola visual kompleks secara otomatis menjadikannya sangat sesuai untuk aplikasi deteksi dan klasifikasi objek dalam berbagai domain.


2.4 Deteksi Objek

Object detection merupakan permasalahan fundamental dan menantang dalam computer vision yang bertujuan mengidentifikasi dan melokalisasi objek dari sejumlah besar kategori yang telah didefinisikan dalam gambar natural [19]. Perkembangan teknologi deteksi objek telah berevolusi dari two-stage detector yang menggunakan arsitektur kompleks untuk seleksi region menuju one-stage detector yang dapat mendeteksi semua region potensial dalam satu tahap, dengan algoritma YOLO menjadi representasi utama one-stage detector yang menawarkan keseimbangan optimal antara akurasi deteksi dan kecepatan inferensi [20].

2.5 YOLOv11

YOLO (You Only Look Once) merupakan algoritma object detection yang dikenalkan secara open source oleh University of Washington untuk memprediksi bounding boxes dan klasifikasinya dari suatu gambar [21]. YOLOv11 merupakan versi terbaru dari keluarga YOLO yang dikembangkan oleh Ultralytics dengan peningkatan signifikan dalam arsitektur backbone dan neck network untuk optimalisasi performa deteksi dengan efisiensi komputasi yang lebih baik [22]. Model ini tersedia dalam berbagai varian (n, s, m, l, x) dengan trade-off antara kecepatan dan akurasi, dimana YOLOv11n cocok untuk aplikasi real-time dengan kebutuhan komputasi yang efisien dan mampu mencapai mAP hingga 39.5% pada dataset COCO [23].

Untuk memahami cara kerja algoritma YOLO secara detail, berikut ini akan dijelaskan arsitektur model YOLO yang menjadi dasar pengembangan YOLOv11. Arsitektur YOLO menerapkan pendekatan one-stage detection yang memungkinkan deteksi objek dilakukan dalam satu tahap proses inference.



Gambar 2. Arsitektur Metode YOLO (You Only Look Once) [21]

Gambar 2 menunjukkan arsitektur lengkap metode YOLO yang terdiri dari rangkaian convolutional layers dengan struktur yang hierarkis dan progresif. Arsitektur dimulai dengan input image berukuran 640×640 piksel yang kemudian diproses melalui serangkaian convolutional layers dengan berbagai konfigurasi. Setiap convolutional layer memiliki spesifikasi yang berbeda, dimulai dari Conv Layer dengan ukuran kernel dan stride yang bervariasi untuk mengekstrak fitur pada level yang berbeda. Struktur arsitektur menunjukkan adanya pengurangan dimensi spasial secara bertahap dari 640×640 hingga ukuran yang lebih kecil melalui pooling operations dan stride convolutions. Bagian tengah arsitektur menampilkan beberapa convolutional layers dengan konfigurasi yang kompleks, termasuk layer dengan multiple channels untuk meningkatkan representasi fitur. Pada bagian akhir arsitektur, terdapat fully connected layers yang berperan dalam menghasilkan prediksi final berupa bounding box coordinates, confidence scores, dan class probabilities. Arsitektur ini dirancang untuk memproses seluruh image dalam satu forward pass, memungkinkan deteksi objek secara real-time dengan efisiensi komputasi yang tinggi. Setiap layer dalam arsitektur berkontribusi pada kemampuan model untuk mendeteksi objek pada berbagai skala dan kompleksitas, dari fitur sederhana hingga representasi semantik tingkat tinggi. Evaluasi model dilakukan menggunakan metrik mAP (Mean Average Precision) yang dihitung dengan rumus:

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AveragePrecision_k \tag{1}$$

Dimana n merupakan jumlah total kelas objek yang dideteksi, k merupakan indeks kelas ke-k, dan Average Precision_k merupakan nilai rata-rata precision untuk kelas ke-k yang dihitung berdasarkan kurva precision-recall.



Nilai mAP berkisar antara 0 hingga 1, dimana nilai yang lebih tinggi menunjukkan performa model yang lebih baik.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penelitian pengembangan sistem deteksi kelayakan sampah anorganik menggunakan model YOLOv11 dalam beberapa subbagian sebagai berikut.

3.1 Pengumpulan Data dan Preprocessing Data

Data yang telah terkumpul dari sampah anorganik peserta Bank Sampah 34 Ngasemrejo telah disortir secara manual untuk memastikan kualitas dan kesesuaiannya dengan standar kelayakan bank sampah. Setelah proses penyortiran, dilanjutkan dengan tahap preprocessing data yang mencakup anotasi, splitting, augmentasi, dan resize menggunakan platform Roboflow. Hasil anotasi disimpan dalam file berekstensi .txt yang mencatat informasi kelas, koordinat titik x dan y objek, serta panjang dan lebar dari bounding box [24].

Pengkodean kelas dilakukan dengan aturan bahwa angka 0 mengindikasikan kelas botol plastik layak, angka 1 untuk botol plastik tidak layak, angka 2 untuk duplex layak, angka 3 untuk duplex tidak layak, angka 4 untuk koran layak, dan angka 5 untuk koran tidak layak. Total data yang terhimpun mencapai 2.800 citra yang terdistribusi dalam enam kelas kelayakan sampah anorganik. Distribusi data menunjukkan bahwa kategori botol plastik dan duplex memiliki jumlah data yang seimbang (masing-masing 600 citra per kelas kelayakan), sedangkan kategori koran memiliki 200 citra per kelas kelayakan. Pembagian dataset dilakukan dengan rasio 70:20:10 untuk data training, validation, dan testing. Tabel 2 berikut menunjukkan distribusi dataset per kelas setelah proses splitting.

Tabel 2. Representasi Anotasi Dataset per Kelas

Kelas	Data training	Data validation	Data testing
botol layak	420	120	60
botol tidak layak	420	120	60
duplex layak	420	120	60
duplex tidak layak	420	120	60
koran layak	140	40	20
koran tidak layak	140	40	20

Tabel 2 di atas menunjukkan distribusi dataset yang telah dibagi menjadi tiga subset yaitu training, validation, dan testing untuk setiap kelas kelayakan sampah anorganik. Data training merupakan subset terbesar yang digunakan untuk melatih model YOLOv11, data validation digunakan untuk evaluasi performa selama proses training, sedangkan data testing digunakan untuk menguji performa final model. Distribusi yang seimbang ini penting untuk mencegah bias model terhadap kelas tertentu dan memastikan generalisasi yang baik pada data yang belum pernah dilihat sebelumnya.

3.2 Modal Training YOLOv11

Implementasi model YOLOv11 untuk deteksi kelayakan sampah anorganik dimulai dengan mengimpor library Ultralytics sebagai framework utama untuk deteksi objek berbasis deep learning. Dataset sampah anorganik yang telah melalui tahap preprocessing diakses langsung melalui platform Roboflow yang terintegrasi dengan Google Colab. Model YOLOv11 diinisialisasi dengan bobot pre-trained sebelum dilatih menggunakan dataset sampah anorganik. Training disiapkan dengan pengaturan hyperparameter yang optimal untuk karakteristik dataset. Tabel 3 berikut menunjukkan konfigurasi hyperparameter yang digunakan dalam proses pelatihan model YOLOv11.

Tabel 3. Hyperparameter Pelatihan Model

Hyperparameter	Nilai
Optimizer	AdamW
Learning rate	0,001
Final LR factor	0,01
Momentum	0,9
Epoch	50
Ukuran gambar	640
Warm-up epochs	3
Weight decay	0,0005

Tabel 3 di atas mendeskripsikan pengaturan hyperparameter yang dioptimalkan untuk karakteristik dataset sampah anorganik. Optimizer AdamW dipilih karena kemampuannya dalam menangani sparse gradients yang


umum dijumpai pada task deteksi objek. Learning rate sebesar 0,001 memberikan keseimbangan antara kecepatan konvergensi dan stabilitas training.

Proses pelatihan menghasilkan beberapa metrik evaluasi penting seperti box_loss, cls_loss, mAP50, dan mAP50-95. Box loss menggambarkan seberapa baik model dapat menentukan lokasi pusat objek dan seberapa akurat bounding box yang diprediksi. Classification loss memberikan gambaran seberapa baik model dapat memprediksi kelas kelayakan yang tepat dari objek sampah yang terdeteksi [25]. Tabel 4 berikut menyajikan perkembangan metrik evaluasi selama proses pelatihan model.

Tabel 4. Hasil Pelatihan Model

Epoch	box_loss	cls_loss	mAP50	mAP50-95
1	0.8118	1.698	0.786	0.659
2	0.7993	1.056	0.775	0.65
3	0.7773	0.9351	0.852	0.737
...
48	0.3497	0.1992	0.993	0.954
49	0.3399	0.1994	0.993	0.957
50	0.3394	0.1947	0.994	0.958

Tabel 4 di atas menunjukkan perkembangan performa model dari epoch awal hingga akhir training. Penurunan signifikan box_loss dari 0.8118 menjadi 0.3394 mengindikasikan peningkatan akurasi lokalisasi objek. Nilai mAP50 yang mencapai 0.994 dan mAP50-95 sebesar 0.958 pada epoch terakhir mengonfirmasi bahwa model berhasil mencapai performa deteksi yang sangat baik. Gambar 3 berikut memvisualisasikan perkembangan loss function selama proses pelatihan model.



Gambar 3. Grafik Box Loss dan Grafik Classification Loss

Gambar 3 menunjukkan performa model YOLOv11 dalam mempelajari karakteristik visual sampah anorganik seperti botol plastik, duplex, dan koran. Penurunan konsisten pada loss training dan validation menandakan bahwa model mampu mempelajari fitur visual yang membedakan sampah layak dan tidak layak setor tanpa mengalami overfitting. Konvergensi kedua kurva loss menunjukkan bahwa model telah mencapai keseimbangan optimal dalam proses pelatihan, dengan kemampuan klasifikasi yang akurat terhadap kondisi sampah, baik dalam kategori bersih dan utuh (layak setor) maupun rusak atau terkontaminasi (tidak layak setor).

Tren penurunan pada grafik classification loss menunjukkan peningkatan akurasi model dalam membedakan kelayakan sampah berdasarkan kelasnya. Hal ini mencerminkan kemampuan YOLOv11 dalam menggeneralisasi pola visual untuk klasifikasi sampah botol plastik, duplex, dan koran ke dalam kategori "layak setor" atau "tidak layak setor". Setelah proses pelatihan selesai, evaluasi terhadap data validasi menghasilkan empat metrik evaluasi utama: presisi, recall, mAP50, dan mAP50-95. Tabel 5 berikut menyajikan hasil evaluasi model pada dataset validasi untuk setiap kelas kelayakan sampah.

Tabel 5. Hasil Evaluasi pada Data Validasi


Kelas	P	R	Map50	Map50-95
all	0.983	0.986	0.994	0.958
Botol layak	0.968	0.956	0.991	0.944
Botol tidak layak	0.952	0.958	0.991	0.947
Duplex layak	0.997	1	0.995	0.978
Duplex tidak layak	0.991	1	0.995	0.98
Koran layak	0.995	1	0.995	0.945
Koran tidak layak	0.997	1	0.995	0.956

Tabel 5 di atas menunjukkan performa model yang sangat baik pada semua kelas dengan precision (P) rata-rata 0.983, recall (R) 0.986, mAP50 0.994, dan mAP50-95 0.958. Hasil evaluasi menunjukkan bahwa model YOLOv11 mampu mengklasifikasikan kelayakan sampah dengan akurasi tinggi. Kelas duplex menunjukkan

performa terbaik dengan nilai precision dan recall mencapai nilai sempurna (1.0) untuk beberapa metrik, diikuti oleh kelas koran dan botol plastik. Konsistensi performa yang tinggi di semua kelas mengindikasikan bahwa model tidak bias terhadap kelas tertentu dan mampu menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.


3.3 Evaluasi Model

Pada tahap evaluasi ini, model YOLOv11 terbaik yang telah dilatih untuk mendeteksi kelayakan sampah anorganik akan dievaluasi secara komprehensif menggunakan berbagai metrik kinerja. Proses evaluasi melibatkan analisis confusion matrix, perhitungan nilai presisi, recall, dan mean Average Precision (mAP) untuk mengukur akurasi sistem dalam mengklasifikasikan sampah botol plastik, duplex, dan koran berdasarkan kelayakan setornya di Bank Sampah 34 Ngasemrejo. Confusion matrix yang dihasilkan dari evaluasi model akan divisualisasikan dalam Gambar 4 untuk memberikan gambaran detail tentang performa klasifikasi setiap kategori objek.



Gambar 4. Confusion Matrix


Gambar 4 di atas menunjukkan confusion matrix yang menganalisis akurasi prediksi model untuk setiap kelas kelayakan sampah. Diagonal utama matrix menunjukkan jumlah prediksi yang benar, sedangkan elemen di luar diagonal menunjukkan kesalahan klasifikasi antar kelas. Matrix ini memberikan wawasan mendalam tentang kelas mana yang paling mudah dan sulit dibedakan oleh model. Gambar 5 berikut memvisualisasikan metrik precision dan recall selama proses pelatihan model.



Gambar 5. Grafik Precision dan Grafik Recall

Gambar 5 di atas menampilkan tren peningkatan precision dan recall selama proses pelatihan. Grafik precision menampilkan tren peningkatan yang konsisten seiring dengan bertambahnya jumlah epoch pelatihan. Pola kenaikan bertahap ini mengindikasikan bahwa model YOLOv11 semakin akurat dalam mengidentifikasi sampah anorganik yang benar-benar layak atau tidak layak setor, dengan minimnya prediksi false positive. Grafik recall pada Gambar 5 menunjukkan trajectory yang meningkat secara progresif, mengindikasikan kemampuan model yang semakin baik dalam mendeteksi seluruh objek sampah target yang ada dalam gambar. Nilai recall yang tinggi menandakan bahwa sistem dapat mengidentifikasi sebagian besar sampah botol plastik, duplex, dan koran yang layak setor tanpa melewatkan objek penting.

Konvergensi kedua metrik pada nilai tinggi menunjukkan bahwa model mencapai keseimbangan optimal antara precision dan recall, yang mengindikasikan performa klasifikasi yang robust. Stabilitas kurva pada epoch akhir menunjukkan bahwa model telah mencapai titik konvergensi dan siap untuk implementasi praktis. Gambar 6 berikut menyajikan visualisasi metrik mAP50 dan mAP50-95 yang mengevaluasi kemampuan deteksi model secara komprehensif.



Gambar 6. Grafik mAP50 dan Grafik Map50-95

Gambar 6 di atas menunjukkan perkembangan metrik mAP50 dan mAP50-95 selama proses pelatihan. Metrik mAP50 mengukur rata-rata presisi deteksi dengan threshold Intersection over Union (IoU) minimal 50%, yang menunjukkan akurasi lokalisasi objek sampah dalam gambar. Nilai mAP50 yang tinggi dan stabil pada Gambar 6 mengindikasikan bahwa model mampu melokalisasi objek sampah dengan akurasi yang baik. Sementara itu, mAP50-95 memberikan evaluasi yang lebih komprehensif dengan menggunakan rentang threshold IoU dari 50% hingga 95%, sehingga mengukur kemampuan model dalam mendeteksi objek sampah dengan berbagai tingkat presisi lokalisasi.

Kombinasi kedua metrik pada Gambar 6 memberikan gambaran menyeluruh tentang robustitas sistem deteksi kelayakan sampah anorganik dalam kondisi operasional yang beragam di lapangan. Tren peningkatan yang konsisten pada kedua metrik menunjukkan bahwa model tidak hanya mampu mendeteksi keberadaan objek sampah, tetapi juga dapat melokalisasi posisi objek dengan presisi tinggi. Stabilitas nilai mAP pada epoch akhir mengonfirmasi bahwa model telah mencapai performa optimal dan siap untuk diimplementasikan dalam sistem penilaian kelayakan sampah anorganik di Bank Sampah 34 Ngasemrejo.

3.4 Pengujian

Pengujian citra dilakukan untuk mengevaluasi kemampuan model YOLOv11 dalam mengidentifikasi dan mengklasifikasikan berbagai kategori sampah anorganik berdasarkan kelayakan setornya dalam kondisi nyata di Bank Sampah 34 Ngasemrejo. Data pengujian diambil langsung dari sampah yang akan disetor oleh peserta bank sampah, memberikan representasi autentik dari kondisi operasional sehari-hari. Tabel 6 berikut menyajikan hasil pengujian model YOLOv11 pada sampel citra sampah anorganik dari setiap kategori kelayakan.

Tabel 6. Hasil Pengujian

No	Citra Sampah Anorganik	Prediksi	Aktual	Kesimpulan
1		Botol plastik layak	Botol plastik layak	Berhasil
2		Botol plastik tidak layak	Botol plastik tidak layak	Berhasil
3		Duplex layak	Duplex layak	Berhasil
4		Duplex tidak layak	Duplex tidak layak	Berhasil
5		Koran layak	Koran layak	Berhasil
6		Koran tidak layak	Koran tidak layak	Berhasil

Tabel 6 menunjukkan hasil pengujian model pada enam sampel citra yang mewakili seluruh kategori kelayakan sampah anorganik. Semua prediksi model sesuai dengan label aktual, mengindikasikan akurasi



klasifikasi 100% pada sampel pengujian ini. Model berhasil mengidentifikasi karakteristik visual yang membedakan sampah layak setor dari yang tidak layak setor pada semua kategori.

Keberhasilan pengujian pada seluruh kategori sampah anorganik mengonfirmasi bahwa model YOLOv11 yang telah dilatih memiliki kemampuan generalisasi yang baik dan siap untuk diimplementasikan dalam sistem penilaian kelayakan sampah di Bank Sampah 34 Ngasemrejo. Akurasi 100% pada pengujian ini menunjukkan bahwa algoritma dapat diandalkan untuk membantu petugas bank sampah dalam melakukan seleksi otomatis, mengurangi subjektivitas penilaian manual, dan meningkatkan efisiensi operasional pengelolaan sampah anorganik.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, sistem deteksi kelayakan sampah anorganik menggunakan algoritma YOLOv11 di Bank Sampah 34 Ngasemrejo terbukti mampu memberikan hasil yang sangat memuaskan dalam mengidentifikasi dan mengklasifikasikan kelayakan tiga jenis sampah anorganik, yaitu botol plastik, duplex, dan koran. Model yang dilatih selama 50 epoch mampu mencapai performa tinggi dengan mAP50 sebesar 99% dan mAP50-95 sebesar 95%, serta nilai presisi dan recall masing-masing sebesar 98%. Selain itu, nilai box loss dan classification loss yang relatif rendah, yaitu masing-masing 0.3394 dan 0.1947, menunjukkan efektivitas model dalam meminimalkan kesalahan prediksi. Hasil ini menegaskan bahwa pendekatan berbasis deep learning, khususnya algoritma YOLOv11, sangat potensial untuk diterapkan dalam sistem otomatisasi penilaian kelayakan sampah di lingkungan bank sampah, sehingga dapat membantu panitia dalam meningkatkan efisiensi dan objektivitas proses penyortiran sampah. Meskipun demikian, cakupan sistem ini masih terbatas pada tiga jenis sampah anorganik. Oleh karena itu, perlu adanya pengembangan lebih lanjut untuk memperluas jenis sampah yang dapat dideteksi, seperti kaleng, kardus, dan plastik kemasan. Penambahan dataset pelatihan dengan variasi latar belakang, pencahayaan, sudut pengambilan gambar, dan kondisi sampah yang lebih kompleks juga sangat disarankan agar model memiliki kemampuan generalisasi yang lebih baik. Dengan pengembangan tersebut, sistem ini diharapkan dapat memberikan kontribusi yang lebih besar terhadap pengelolaan sampah yang berkelanjutan dan efisien di berbagai wilayah.

REFERENCES

- [1] OECD, *Global Plastics Outlook*. OECD Publishing, 2022. doi: 10.1787/de747aef-en.
- [2] Y. Zahrah, J. Yu, dan X. Liu, "How Indonesia's Cities Are Grappling with Plastic Waste: An Integrated Approach towards Sustainable Plastic Waste Management," *Sustainability (Switzerland)*, vol. 16, no. 10, Mei 2024, doi: 10.3390/su16103921.
- [3] B. F. Apriadi, R. P. Setiawan, dan I. Firmansyah, "Policy scenario of plastic waste mitigation in Indonesia using system dynamics," *Waste Management & Research: The Journal for a Sustainable Circular Economy*, vol. 42, no. 11, hlm. 1008–1018, Nov 2024, doi: 10.1177/0734242X241231396.
- [4] A. Budiarto, B. Clarke, dan K. Ross, "Overview of waste bank application in Indonesian regencies," *Waste Management & Research: The Journal for a Sustainable Circular Economy*, vol. 43, no. 3, hlm. 306–321, Mar 2025, doi: 10.1177/0734242X241242697.
- [5] A. Abdillah, I. Widianingsih, R. A. Buchari, dan H. Nurasa, "Trends community-based waste management practice through waste bank in Indonesia: towards local environmental resilience," *Local Environ*, vol. 29, no. 8, hlm. 1004–1007, Agu 2024, doi: 10.1080/13549839.2024.2353043.
- [6] M. R. Ismiraj, A. Wulansari, Y. Setiadi, A. Pratama, dan N. Mayasari, "Perceptions of Community-Based Waste Bank Operators and Customers on Its Establishment and Operationalization: Cases in Pangandaran, Indonesia," *Sustainability*, vol. 15, no. 14, hlm. 11052, Jul 2023, doi: 10.3390/su151411052.
- [7] D. Triyanto, M. Zidan, M. Wahyudi, L. Pujiastuti, dan S. Sumanto, "Pengembangan Sistem Deteksi Objek Botol Real-Time dengan YOLOv8 untuk Aplikasi Vision," *Indonesian Journal Computer Science*, vol. 3, no. 1, hlm. 44–50, Apr 2024, doi: 10.31294/ijcs.v3i1.6070.
- [8] N. L. Kirana, D. Kurnianingtyas, dan . Indriati, "A Deep Learning Approach to Plastic Bottle Waste Detection on the Water Surface using YOLOv6 and YOLOv7," *Engineering, Technology & Applied Science Research*, vol. 14, no. 6, hlm. 18623–18630, Des 2024, doi: 10.48084/etasr.8592.
- [9] H. Oktafiandi, "Implementasi Algoritma Convolution Neural Network pada Klasifikasi Limbah dengan Arsitektur MobileNet," Apr 2023. doi: 10.56655/winco.v4i1.196.
- [10] M. Haqqi, L. Rochmah, A. D. Safitri, R. A. Pratama, dan Tarwoto, "Implementation Of Machine Learning To Identify Types Of Waste Using CNN Algorithm," *JURNAL FASILKOM*, vol. 14, no. 3, hlm. 761–765, Des 2024, doi: 10.37859/jf.v14i3.8116.
- [11] S. R. Sausan Claudia dan Y. P. Astuti, "Penerapan Algoritma Deep Learning CNN untuk Klasifikasi Pemilahan Sampah," *JTERA (Jurnal Teknologi Rekayasa)*, vol. 8, no. 2, hlm. 183, Jan 2024, doi: 10.31544/jtera.v8.i2.2023.183-190.
- [12] P. Li, J. Xu, dan S. Liu, "Solid Waste Detection Using Enhanced YOLOv8 Lightweight Convolutional Neural Networks," *Mathematics*, vol. 12, no. 14, hlm. 2185, Jul 2024, doi: 10.3390/math12142185.
- [13] N. L. Kirana, D. Kurnianingtyas, dan . Indriati, "A Deep Learning Approach to Plastic Bottle Waste Detection on the Water Surface using YOLOv6 and YOLOv7," *Engineering, Technology & Applied Science Research*, vol. 14, no. 6, hlm. 18623–18630, Des 2024, doi: 10.48084/etasr.8592.



- [14] L. Chen dan J. Zhu, “Water surface garbage detection based on lightweight YOLOv5,” *Sci Rep*, vol. 14, no. 1, hlm. 6133, Mar 2024, doi: 10.1038/s41598-024-55051-3.
- [15] H. Heng, F. Meng, dan J. McKechnie, “Wind turbine blade wastes and the environmental impacts in Canada,” *Waste Management*, vol. 133, hlm. 59–70, Sep 2021, doi: 10.1016/j.wasman.2021.07.032.
- [16] P.-C. Kuo, B. Illathukandy, C.-H. Kung, J.-S. Chang, dan W. Wu, “Process simulation development of a clean waste-to-energy conversion power plant: Thermodynamic and environmental assessment,” *J Clean Prod*, vol. 315, hlm. 128156, Sep 2021, doi: 10.1016/j.jclepro.2021.128156.
- [17] B. Madden, N. Florin, S. Mohr, dan D. Giurco, “Spatial modelling of municipal waste generation: Deriving property lot estimates with limited data,” *Resour Conserv Recycl*, vol. 168, hlm. 105442, Mei 2021, doi: 10.1016/j.resconrec.2021.105442.
- [18] A. Dhillon dan G. K. Verma, “Convolutional neural network: a review of models, methodologies and applications to object detection,” *Progress in Artificial Intelligence*, vol. 9, no. 2, hlm. 85–112, Jun 2020, doi: 10.1007/s13748-019-00203-0.
- [19] L. Liu dkk., “Deep Learning for Generic Object Detection: A Survey,” *Int J Comput Vis*, vol. 128, no. 2, hlm. 261–318, Feb 2020, doi: 10.1007/s11263-019-01247-4.
- [20] U. Sirisha, S. P. Praveen, P. N. Srinivasu, P. Barsocchi, dan A. K. Bhoi, “Statistical Analysis of Design Aspects of Various YOLO-Based Deep Learning Models for Object Detection,” *International Journal of Computational Intelligence Systems*, vol. 16, no. 1, hlm. 126, Agu 2023, doi: 10.1007/s44196-023-00302-w.
- [21] J. Redmon, S. Divvala, R. Girshick, dan A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” Mei 2016. [Daring]. Tersedia pada: <http://pjreddie.com/yolo/>
- [22] L. He, Y. Zhou, L. Liu, W. Cao, dan J. Ma, “Research on object detection and recognition in remote sensing images based on YOLOv11,” *Sci Rep*, vol. 15, no. 1, hlm. 14032, Apr 2025, doi: 10.1038/s41598-025-96314-x.
- [23] Y. Li, P. Sun, H. Qi, dan S. Lyu, “LandmarkBreaker: A proactive method to obstruct DeepFakes via disrupting facial landmark extraction,” *Computer Vision and Image Understanding*, vol. 240, hlm. 103935, Mar 2024, doi: 10.1016/j.cviu.2024.103935.
- [24] A. Sani dan S. Rahmadinni, “Deteksi Gestur Tangan Berbasis Pengolahan Citra,” *Jurnal Rekayasa Elektrika*, vol. 18, no. 2, Jul 2022, doi: 10.17529/jre.v18i2.25147.
- [25] M. Kasper-Eulaers, N. Hahn, S. Berger, T. Sebulonsen, Ø. Myrland, dan P. E. Kummervold, “Short Communication: Detecting Heavy Goods Vehicles in Rest Areas in Winter Conditions Using YOLOv5,” *Algorithms*, vol. 14, no. 4, hlm. 114, Mar 2021, doi: 10.3390/a14040114.