

Sistem Klasifikasi Sampah Anorganik Menggunakan Metode YOLOv12

Muhammad Wildan Adhani¹, Daniel Sutopo Pamungkas¹

¹Program Studi Mekatronika, Jurusan Teknik Elektro, Politeknik Negeri Batam, Batam, Indonesia

*Email : wildanadhani272@gmail.com

Abstract— Effective inorganic waste management has become a crucial challenge in the effort to maintain environmental sustainability. One applicable solution is an automated system for classifying inorganic materials to support the recycling process. This research develops an inorganic material classification system using the You Only Look Once version 12 (YOLOv12) method, an object detection model based on deep learning known for its high speed and accuracy. The research process begins with the collection of an image dataset to recognize several types of inorganic waste. This dataset is then labeled and used to train the YOLOv12 model. The model is trained using data augmentation techniques and hyperparameter tuning to improve detection performance. System evaluation is conducted using precision, recall, and mean Average Precision (mAP) metrics. The test results show that the YOLOv12 method is capable of classifying inorganic materials with high accuracy and fast inference time. In addition to presenting the test metric results, this study also provides a comprehensive analysis of the model's performance—such as its reliability under various environmental and physical object conditions—to thoroughly evaluate the limits of the system's capabilities. This makes it an efficient solution for automated waste sorting systems. Although focused on software design, the resulting detection system is expected to serve as a potential initial step for integration into automated sorting hardware. Thus, this system will ultimately support the recycling process to run more efficiently and effectively, reduce environmental pollution, and increase the economic value of inorganic materials.

Index Terms— YOLOv12, inorganic material classification, object detection, deep learning, recycling..

Abstrak— Pengelolaan sampah anorganik yang efektif menjadi tantangan penting dalam upaya menjaga kelestarian lingkungan. Salah satu solusi yang dapat diterapkan adalah sistem otomatis untuk klasifikasi bahan anorganik guna mendukung proses daur ulang. Penelitian ini mengembangkan sistem klasifikasi bahan anorganik menggunakan metode You Only Look Once versi 12 (YOLOv12), sebuah model deteksi objek berbasis deep learning yang dikenal dengan kecepatannya dan akurasi yang tinggi. Proses penelitian dimulai dengan pengumpulan dataset gambar untuk mengenali beberapa jenis sampah anorganik. Dataset ini kemudian dilabeli dan digunakan untuk melatih model YOLOv12. Model dilatih dengan teknik augmentasi data serta tuning hyperparameter guna meningkatkan performa deteksi. Evaluasi sistem dilakukan menggunakan metrik precision, recall, dan mean Average Precision (mAP). Hasil pengujian menunjukkan bahwa metode YOLOv12 mampu mengklasifikasikan bahan anorganik dengan akurasi tinggi serta waktu inferensi yang cepat. Selain pemaparan hasil metrik pengujian, penelitian ini juga menyajikan analisis komprehensif terhadap performa model seperti keandalannya pada berbagai kondisi lingkungan dan fisik objek untuk mengevaluasi batas kapabilitas sistem secara mendalam. Hal ini menjadikannya solusi yang efisien untuk sistem otomatisasi pemilahan sampah. Meskipun difokuskan pada perancangan perangkat lunak, sistem deteksi yang dihasilkan diharapkan dapat menjadi langkah awal yang potensial untuk diintegrasikan pada perangkat keras pemilah otomatis. Dengan demikian, sistem ini pada akhirnya akan mendukung proses daur ulang agar berjalan lebih efisien dan efektif, mengurangi pencemaran lingkungan, serta meningkatkan nilai ekonomi bahan anorganik.

Kata Kunci— YOLOv12, klasifikasi sampah anorganik, deteksi objek, deep learning.

I. LATAR BELAKANG

Pengelolaan sampah merupakan salah satu tantangan utama yang dihadapi oleh masyarakat saat ini dalam upaya menjaga kebersihan lingkungan dan melindungi sumber daya alam. Pertumbuhan populasi yang cepat, perubahan gaya hidup, dan konsumsi yang meningkat telah menyebabkan peningkatan volume sampah yang dihasilkan. Oleh karena itu, penting untuk mengembangkan solusi yang efektif dalam mengelola sampah agar dapat mencapai lingkungan yang bersih dan berkelanjutan.

Menurut Kementerian Lingkungan Hidup dan Kehutanan berdasarkan data dari Sistem Informasi Pengolahan Sampah Nasional (SIPSN), pada tahun 2022 timbunan sampah di Indonesia mencapai 38 juta ton, dan pada tahun 2023 timbunan sampah semakin meningkat mencapai 41 juta ton. Lalu pada data yang terbaru menunjukkan bahwa jumlah sampah yang dihasilkan mencapai 67 juta ton per tahun. Data tersebut menjadi bukti bahwa Indonesia sedang menghadapi tantangan yang besar dalam mengatasi permasalahan sampah [1]. Sampah yang berpotensi dapat didaur ulang dan memiliki nilai jual adalah sampah anorganik terutama sampah kardus, logam, kertas, plastik, karet dan sampah lainnya seperti kemasan produk. Berbagai jenis Sampah ini dapat diklasifikasikan menggunakan model pembelajaran mesin

Di era teknologi saat ini, kecerdasan buatan (*Artificial Intelligence*) semakin berkembang, termasuk dalam bidang *computer vision*. Salah satu metode yang banyak digunakan untuk mendeteksi dan mengenali objek dalam gambar adalah *You Only Look Once* (YOLO). YOLO merupakan salah satu model deep learning yang bertujuan untuk mengenali objek-objek. Metode YOLOv12 adalah sebuah model metode YOLO Versi terbaru yang memiliki kemampuan untuk memberikan tingkat akurasi yang tinggi, meminimalkan kebutuhan komputasi, serta memiliki kemampuan untuk mendeteksi beberapa objek dalam satu citra [2].

Berdasarkan beberapa penelitian sebelumnya yang telah dilakukan dalam bidang klasifikasi sampah, masih terdapat sejumlah keterbatasan yang dapat dikembangkan lebih lanjut.

Penelitian yang dilakukan oleh Hanif Abdillah dan rekan-rekannya menggunakan metode YOLOv5 berbasis web untuk klasifikasi sampah organik dan anorganik menunjukkan hasil yang cukup baik dengan akurasi mencapai 86%. Namun, penelitian ini masih memiliki beberapa kelemahan, di antaranya adalah ukuran dataset yang relatif kecil, yakni hanya terdiri dari 200 gambar. Jumlah tersebut tidak cukup mewakili keragaman jenis sampah yang ada di masyarakat, sehingga kemampuan model dalam melakukan generalisasi masih terbatas. Selain itu, klasifikasi yang dilakukan masih bersifat umum karena hanya membedakan dua kategori utama, yaitu organik dan anorganik, tanpa menjelaskan jenis-jenis spesifik di dalamnya [3].

Penelitian lain oleh Parole Nimadinaga Dacipta dan Ricky Eka Putra menggunakan metode CNN pada *web service* berbasis *Flask* dan memperoleh akurasi sebesar 69,77%. Meskipun ini merupakan langkah awal yang positif, namun tingkat akurasi yang tergolong rendah membuat sistem kurang optimal untuk digunakan dalam pengelolaan sampah secara otomatis. Keterbatasan lain terletak pada penggunaan metode CNN dasar yang kurang efisien dibandingkan metode deteksi objek terkini seperti YOLO [4].

Tegar Danuarta Kusuma dan timnya mengembangkan sistem deteksi sampah plastik di perairan menggunakan drone berbasis AI dan berhasil mencapai akurasi hingga 90%. Meskipun hasilnya tinggi, sistem ini hanya fokus pada satu jenis sampah, yaitu plastik, dan efektivitasnya sangat bergantung pada kondisi cuaca serta kualitas gambar udara, yang dapat menjadi tantangan besar dalam penerapannya di lapangan [5].


Melihat peluang dari berbagai kekurangan tersebut, saya bermaksud untuk mengajukan proposal penelitian yang berfokus pada pengembangan sistem klasifikasi sampah anorganik secara real-time menggunakan metode YOLOv12. Sistem ini dirancang untuk dapat mendeteksi dan mengklasifikasikan sampah botol Kaca, botol plastik, kaleng minuman, serta gelas dan kotak makanan berbahan *styrofoam*. Output dari sistem ini berupa tampilan visual di layar yang menunjukkan jenis material dari botol atau gelas yang terdeteksi,

beserta nilai akurasi dari masing-masing klasifikasi. Sistem ini tidak mencakup proses pemilahan fisik sampah, melainkan hanya terbatas pada tahap identifikasi dan klasifikasi berbasis citra. Melalui penelitian ini, diharapkan dapat dikembangkan sebuah sistem klasifikasi sampah anorganik yang lebih spesifik dan akurat.

II. METODE PENELITIAN

A. Rancangan Penelitian

Dalam merancang sebuah sistem, diperlukan suatu metode pelaksanaan agar rancangan penelitian yang dibuat terstruktur dan jelas. Tahapan-tahapan dalam pelaksanaan ini tentunya harus efektif dan efisien. Sehingga tidak membuang banyak biaya dan waktu secara percuma. Berikut merupakan diagram alir metode pelaksanaan pembuatan system.



Gambar 1. Flowchart Metode Penelitian

B. Pengumpulan Data Image


Tahap pengumpulan data bertujuan untuk membangun dataset komprehensif yang akan dipelajari oleh model. Dataset yang dihimpun berjumlah total 7.006 citra digital (format .JPG) yang merepresentasikan empat kelas utama sampah anorganik: botol kaca (1.560 citra), botol plastik (1.898 citra), kaleng (1.837 citra), dan *styrofoam* (1.711 citra). Pengumpulan data diimplementasikan melalui kombinasi dua metode, yakni pengambilan citra secara langsung menggunakan kamera di lapangan (mencakup 63% dari total data) serta pengumpulan dataset tambahan melalui sumber internet yang relevan (43%). Untuk memastikan model memiliki kemampuan generalisasi yang baik di dunia nyata, pengambilan gambar dilakukan secara variatif, baik di dalam ruangan (*indoor*) maupun di luar ruangan (*outdoor*). Variasi ini mencakup perbedaan jarak objek (dekat hingga sedang), kondisi pencahayaan (terang dan redup), sudut pandang kamera dari atas, serta jumlah objek dalam satu *frame*, dengan tetap menjaga kualitas citra dari pantulan cahaya atau bayangan yang berlebihan.



Gambar 2. Contoh Pengumpulan Dataset

C. Pelabelan Dataset (Labeling)

Setelah data terkumpul, proses pelabelan (*labeling*) atau pemberian anotasi dilakukan secara manual pada masing-masing citra menggunakan platform *computer vision* berbasis web, Roboflow. Setiap objek pada citra ditandai dengan *bounding box* yang presisi dan diberikan kelas label yang sesuai (botol kaca, botol plastik, kaleng, atau *styrofoam*). Selain memfasilitasi penggambaran *bounding box*, Roboflow juga digunakan untuk manajemen dataset seperti penyimpanan, penyortiran, dan pengeksporan (*export*) data ke dalam format yang secara native kompatibel dengan algoritma YOLO. Kualitas pelabelan ini sangat krusial karena secara langsung menentukan seberapa akurat model mampu mengidentifikasi fitur objek selama proses pelatihan.



Gambar 3. Proses Pelabelan Dataset

D. Prapemrosesan Dataset (Preprocessing)

Sebelum memasuki tahap pelatihan, dataset harus melalui tahap prapemrosesan agar format dan kualitasnya seragam. Pada penelitian ini, seluruh citra disesuaikan ukurannya (*image resizing*) secara konsisten menjadi dimensi 640 $\times$ 640 piksel, yang merupakan standar dimensi input optimal untuk arsitektur YOLOv12. Penyeragaman resolusi ini sangat vital untuk mengurangi beban dan kompleksitas komputasi—terutama pada citra beresolusi sangat tinggi—sehingga proses ekstraksi fitur berjalan jauh lebih efisien, stabil, dan tidak memakan waktu pelatihan yang terlalu lama.

E. Augmentasi Dataset

Guna melipatgandakan variasi data tanpa harus menambah pengambilan gambar fisik, diterapkan serangkaian teknik augmentasi selama proses pelatihan (*training*). Augmentasi ini bertujuan untuk membuat model lebih tangguh (*robust*) terhadap berbagai anomali atau perubahan kondisi lingkungan. Modifikasi yang diterapkan mencakup pembalikan citra (*flip horizontal/vertical*) untuk melatih model mengenali objek dari berbagai orientasi arah, serta modifikasi tingkat eksposur kecerahan sebesar $\pm 25\%$ guna menyimulasikan kondisi lingkungan yang terlalu terang (*overexposed*) atau terlalu gelap (*underexposed*). Selain itu, dilakukan penambahan gangguan acak berupa Gaussian noise sebesar 2% agar model beradaptasi terhadap penurunan kualitas gambar akibat kompresi atau sensor kamera yang buruk. Sebagai tambahan, model juga dilatih dengan pemutaran citra (*rotate*) pada sudut 90° agar adaptif terhadap objek yang posisinya tidak tegak lurus, serta pemberian efek buram (*blur*) sebesar 2,5 piksel untuk menyimulasikan gambar yang kehilangan fokus atau mengalami motion blur akibat pergerakan kamera.

F. Pembagian Dataset

Dari total 7.006 citra yang telah diproses, dataset dibagi secara proporsional ke dalam tiga himpunan dengan rasio 70:20:10. Secara rinci, 4.904 citra dialokasikan sebagai data pelatihan (*Training Set*) agar model dapat mempelajari karakteristik kelas objek; 1.401 citra sebagai data validasi (*Validation Set*) untuk memantau peningkatan performa dan mencegah terjadinya fenomena *overfitting* pada setiap epoch; serta 701 citra sebagai data pengujian (*Testing Set*) yang digunakan di akhir fase untuk menguji performa prediksi model

terhadap data yang benar-benar belum pernah dilihat sebelumnya.

No	Kelas	Jumlah Objek (Instances)	Persentase (%)
1	Botol Kaca	1.560	22,27%
2	Botol Plastik	1.898	27,09%
3	Kaleng	1.837	26,22%
4	Styrofoam	1.711	24,22%
Total		7006	100%

Gambar 4. Tabel Pembagian Dataset

G. Pelatihan Model (Training)

Implementasi pelatihan model YOLOv12 dieksekusi memanfaatkan kapabilitas akselerasi Graphical Processing Unit (GPU) pada lingkungan cloud Google Colab. Proses ini dimulai dengan menggunakan bobot awal bawaan YOLOv12 (*yolov12n.pt*) guna mempercepat konvergensi algoritma melalui *transfer learning*. Parameter teknis yang diatur mencakup ukuran batch (*batch size*) sebesar 64, ukuran gambar 640 $\times$ 640 piksel, pemanfaatan cache pada memori untuk mempercepat akses data, dan penggunaan file konfigurasi *data.yaml* untuk merujuk kelas dataset. Eksperimen pelatihan diuji secara mendalam dengan variasi iterasi (*epochs*) yang berbeda, yakni 100, 150, 200, dan 300 epoch, guna membandingkan dan memperoleh arsitektur model dengan performa deteksi paling optimal. Model terlatih terbaik nantinya akan disimpan dengan ekstensi *.pt*.

H. Evaluasi Model

Kinerja model terlatih divalidasi terhadap data testing untuk mengukur seberapa akurat sistem mengenali dan membedakan jenis-jenis sampah anorganik. Evaluasi kuantitatif dianalisis berdasarkan Confusion Matrix yang memetakan tebakan prediksi terhadap nilai aktual kelas objek. Dari matriks tersebut, diturunkan beberapa parameter metrik standar evaluasi machine learning, yakni Tingkat Akurasi (*Accuracy*), Presisi (*Precision*), Sensitivitas (*Recall*), serta mean Average Precision (*mAP*) untuk menilai keandalan deteksi secara keseluruhan.

	KELAS	PREDICTED				
		Botol Plastik (A)	Botol Kaca (B)	Kaleng (C)	Styrofoam (D)	Background
ACTUAL	Botol Plastik (A)	TP (A)	FP (B) FN (A)	FP (C) FN (A)	FP (D) FN (A)	FN (A)
	Botol Kaca (B)	FP (A) FN (B)	TP (B)	FP (C) FN (B)	FP (D) FN (B)	FN (B)
	Kaleng (C)	FP (A) FN (C)	FP (B) FN (C)	TP (C)	FP (D) FN (C)	FN (C)
	Styrofoam (D)	FP (A) FN (D)	FP (B) FN (D)	FP (C) FN (D)	TP (D)	FN (D)
	Background	FP (A)	FP (B)	FP (C)	FP (D)	TN

Gambar 5. Confusion Matrix Multi Kelas

Dalam sistem deteksi sampah anorganik berbasis YOLOv12 ini, fokus pengujian hanya dilakukan pada 4 kelas utama, yaitu: Botol Plastik (A), Botol Kaca (B), Kaleng (C), dan Styrofoam (D). Kelas *Background* tidak dihitung sebagai kelas yang dievaluasi metriknya secara mandiri. Kelas ini hanya berfungsi sebagai wadah untuk menampung dua jenis kesalahan Sebagai *False Negative* (FN) Jika objek dari 4 kelas utama masuk ke kolom *Background*, ini berarti model gagal mendeteksi objek tersebut sama sekali (*missed detection*) & *False Positive* (FP) Jika model menebak ada objek (A/B/C/D) pada area yang kosong, tebakan tersebut akan masuk ke baris *Background*. Ini berarti model memberikan deteksi palsu (*false alarm*).

Berdasarkan nilai-nilai tersebut, beberapa metrik evaluasi dapat dihitung, di antaranya:

1. Accuracy (Akurasi)

Mengukur proporsi prediksi yang benar terhadap total keseluruhan data.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. *Precision* (Presisi)

Mengukur tingkat ketepatan model dalam mengklasifikasikan data positif.

$$Precision = \frac{TP}{TP + FP}$$

3. *Recall* (Sensitivitas)

Mengukur kemampuan model dalam menemukan semua data positif yang benar.

$$Recall = \frac{TP}{TP + FN}$$

4. *F1-Score*

Merupakan nilai rata-rata harmonis antara *Precision* dan *Recall*. Metrik ini sangat ideal digunakan untuk melihat keseimbangan performa model, terutama jika ada ketidakseimbangan jumlah data antar kelas atau jika FP dan FN sama-sama krusial untuk ditekan.

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

Dalam penelitian ini, Confusion Matrix digunakan untuk mengevaluasi performa model deteksi dan klasifikasi sampah anorganik berbasis metode YOLOv12. Dengan menggunakan *Confusion Matrix*, dapat diketahui seberapa akurat model dalam mengidentifikasi jenis-jenis sampah seperti botol plastik, kaleng, styrofoam, dan botol kaca

III. HASIL & PEMBAHASAN

Hasil dan pembahasan berisi data yang harus diketahui dalam penelitian ini. Pengambilan data memiliki tujuan untuk membuktikan bahwa penelitian ini sesuai dengan tujuan yang diharapkan.

Penelitian ini mengembangkan dan menguji model deteksi objek untuk mengklasifikasikan empat kategori sampah anorganik, yaitu botol plastik, botol kaca, kaleng, dan styrofoam. Rangkaian pengujian yang dilakukan tidak sekadar bertujuan melaporkan angka akurasi, melainkan untuk memetakan secara sistematis pada kondisi seperti apa model bekerja optimal dan pada kondisi seperti apa model mengalami degradasi performa. Pola inilah yang menjadi inti pembahasan berikut: bagaimana karakteristik data, kondisi lingkungan pengambilan citra, dan sifat fisik material saling berinteraksi memengaruhi keandalan sistem deteksi berbasis deep learning.

No	Percobaan	Kelas	mAP	Precision	Recall	F1-score
1	100 epoch	Botol kaca	94.9%	0.939	0.928	0.933
		Botol Plastik		0.930	0.863	0.895
		Kaleng		0.911	0.941	0.926
		Styrofoam		0.948	0.936	0.942
2	150 epoch	Botol kaca	95.6%	0.958	0.888	0.922
		Botol Plastik		0.996	0.807	0.892
		Kaleng		0.992	0.977	0.984
		Styrofoam		0.966	0.960	0.963
3	200 epoch	Botol kaca	94%	0.938	0.913	0.925
		Botol Plastik		0.917	0.858	0.886
		Kaleng		0.923	0.935	0.929
		Styrofoam		0.942	0.922	0.932
4	300 Epoch	Botol kaca	93.4%	0.938	0.895	0.915
		Botol Plastik		0.911	0.843	0.876
		Kaleng		0.927	0.921	0.924
		Styrofoam		0.945	0.907	0.926


Gambar 6. Perbandingan Performa Epoch

Pengujian terhadap empat variasi jumlah epoch (100, 150,

200, dan 300) menunjukkan pola yang tidak linear: performa model meningkat dari 100 ke 150 epoch, namun kemudian menurun secara konsisten pada 200 dan 300 epoch meskipun jumlah iterasi pelatihan bertambah jauh lebih banyak. Pola non-monoton ini secara substantif lebih penting untuk dibahas dibandingkan sekadar melaporkan bahwa 150 epoch adalah konfigurasi terbaik.

Temuan ini merupakan indikasi empiris dari fenomena saturasi pembelajaran (learning saturation) yang mengarah pada overfitting ringan. Ketika model dilatih melampaui titik optimalnya, ia cenderung mulai menghafal pola-pola spesifik pada data latih alih-alih mempelajari fitur umum yang dapat digeneralisasi ke data baru. Hal ini konsisten dengan prinsip bias-variance trade-off yang telah lama menjadi landasan teori dalam pembelajaran mesin: penambahan kapasitas atau durasi pelatihan tanpa batas tidak selalu berbanding lurus dengan peningkatan kemampuan generalisasi, dan pada titik tertentu justru menurunkan performa pada data uji baru walau performa pada data latih terus membaik.

Secara akademik, temuan ini memberi kontribusi praktis bagi riset deteksi sampah berbasis citra: durasi pelatihan yang optimal bersifat spesifik-dataset dan tidak dapat diasumsikan “semakin lama semakin baik”. Pola ini menegaskan pentingnya strategi early stopping atau validasi berkala selama pelatihan, alih-alih menetapkan jumlah epoch secara sewenang-wenang di awal proses.



Gambar 7. Confussion Matrix 150 Epoch

Analisis lebih mendalam terhadap confusion matrix pada seluruh variasi epoch, termasuk model terbaik (150 epoch), memperlihatkan pola yang konsisten: kesalahan antar-kelas objek (misalnya kaleng terdeteksi sebagai botol plastik) relatif jarang terjadi, sedangkan kesalahan berupa objek yang gagal terdeteksi dan justru diklasifikasikan sebagai background jauh lebih dominan. Pada model terbaik sekalipun, ratusan objek botol kaca dan botol plastik masih jatuh ke kategori background.

Pola ini mengindikasikan bahwa persoalan utama model bukan terletak pada kemampuan diskriminasi antarkelas (classification), melainkan pada kemampuan lokalisasi dan deteksi keberadaan objek itu sendiri (objectness). Dengan kata lain, begitu model berhasil “melihat” suatu objek, ia hampir selalu mampu mengklasifikasikannya dengan benar; masalah muncul justru pada tahap sebelumnya, yaitu ketika fitur objek tidak cukup menonjol untuk dibedakan dari latar belakang.

```
Validating /content/runs/detect/train/weights/best.pt...
Ultralytics 8.4.29 Python-3.12.13 torch-2.10.0+cu128 CUDA:0 (Tesla T4, 14913MiB)
YOLO12n summary (fused): 159 layers, 2,557,508 parameters, 0 gradients, 6.3 GFLOPs
```

Class	Images	Instances	Box(P)	R	mAP50	mAP50-95
all	923	10844	0.978	0.908	0.956	0.869
Botol Kaca	201	232	0.958	0.888	0.931	0.738
Botol Plastik	238	285	0.996	0.807	0.927	0.848
Kaleng	258	261	0.992	0.977	0.993	0.98
Styrofoam	228	266	0.966	0.96	0.974	0.91

Speed: 0.2ms preprocess, 4.2ms inference, 0.0ms loss, 2.3ms postprocess per image
Results saved to /content/runs/detect/train

Gambar 8. Hasil Performa 150 Epoch

Fakta bahwa botol kaca dan botol plastik secara konsisten menjadi kelas dengan tingkat kegagalan deteksi tertinggi di seluruh skenario pengujian memperkuat interpretasi ini. Kedua material tersebut memiliki sifat transparan dan reflektif yang membuat tepi (edge) dan tekstur objek—fitur visual utama yang menjadi dasar ekstraksi fitur pada jaringan konvolusional—menjadi lemah atau tersamarkan oleh pantulan cahaya dan latar di baliknya. Sebaliknya, kaleng dan styrofoam yang memiliki permukaan buram dengan kontras warna dan bentuk yang lebih stabil justru menunjukkan performa deteksi paling konsisten di hampir semua kondisi pengujian. Ini sejalan dengan tantangan yang secara umum diakui dalam literatur deteksi objek berbasis citra, bahwa material transparan dan reflektif merupakan salah satu kasus paling sulit bagi model computer vision konvensional karena minimnya sinyal tekstur yang dapat diandalkan.

Kontribusi akademik dari temuan ini adalah penegasan bahwa evaluasi model deteksi objek berbasis material daur ulang tidak dapat hanya berhenti pada metrik agregat seperti mAP atau akurasi keseluruhan, melainkan perlu diuraikan per kelas untuk mengungkap kerentanan spesifik yang berkorelasi dengan sifat fisik material—suatu wawasan yang relevan bagi pengembangan sistem persampahan otomatis berbasis kecerdasan buatan di masa mendatang.

Jarak	Precision	Recall	F1-score	Accuracy
50 cm	95.54%	90.83%	93.11%	90.83%
100 cm	91.22%	87.50%	89.25%	87.50%
200 cm	87.03%	75.00%	80.27%	75.00%
300 cm	80.95%	48.33%	60.42%	48.33%

Gambar 9. Performa Pengujian Jarak Deteksi

Pengujian pada variasi jarak menunjukkan penurunan akurasi keseluruhan yang tajam dan hampir linear seiring bertambahnya jarak objek dari kamera: dari 90,83% pada jarak 50 cm menjadi hanya 48,33% pada jarak 300 cm. Pola penurunan ini jauh lebih curam dibandingkan pola penurunan pada variasi pengujian lainnya, menjadikan jarak sebagai salah satu faktor lingkungan paling kritis dalam penelitian ini.

Interpretasi mendasar dari temuan ini berkaitan dengan konsep resolusi efektif objek dalam citra. Semakin jauh jarak objek dari sensor kamera, semakin kecil proporsi piksel yang merepresentasikan objek tersebut dalam frame, sehingga informasi visual (tekstur, tepi, gradasi warna) yang tersedia bagi jaringan untuk diekstraksi menjadi semakin terbatas. Ini bukan sekadar persoalan “objek menjadi kecil”, melainkan persoalan hilangnya informasi diskriminatif pada level piksel yang menjadi dasar seluruh proses ekstraksi fitur pada arsitektur deep learning berbasis citra.

Implikasi akademik dari temuan ini adalah bahwa klaim keandalan suatu model deteksi sampah tidak dapat digeneralisasi tanpa mempertimbangkan jarak operasional. Untuk konteks penerapan nyata—misalnya sistem penyortiran otomatis pada jalur conveyor atau tempat pembuangan sampah—hasil ini menyiratkan bahwa desain penempatan kamera perlu membatasi jarak efektif hingga sekitar 100–200 cm agar tingkat keandalan tetap berada pada rentang yang dapat diterima, sekaligus membuka ruang penelitian lanjutan mengenai teknik super-resolution atau multi-scale feature extraction untuk memperluas jangkauan deteksi yang andal.

Pencahayaan	Precision	Recall	F1-score	Accuracy
<50 lux	83.32%	75.00%	78.63%	75.00%
51 - 100 Lux	90.53%	86.67%	88.56%	86.67%
> 100 Lux	88.31%	87.50%	87.86%	87.50%

Gambar 11. Hasil Pengujian Pencahayaan

Pada variasi kondisi cahaya, model menunjukkan penurunan performa paling nyata pada kondisi minim cahaya (<50 lux) dengan

akurasi 75%, dibandingkan kondisi cahaya sedang (86,67%) dan terang (87,5%). Menariknya, selisih performa antara kondisi cahaya sedang dan terang relatif kecil, sedangkan penurunan paling tajam justru terjadi ketika cahaya berada di bawah ambang tertentu.

Pola ini mengindikasikan adanya ambang kontras minimum yang dibutuhkan model untuk dapat mengekstraksi fitur secara andal, bukan hubungan linear sederhana antara intensitas cahaya dan akurasi. Pada kondisi minim cahaya, citra cenderung memiliki kontras rendah dan derau (noise) yang lebih tinggi, yang menyamarkan batas antara objek dan latar belakang—kondisi yang secara umum diketahui menjadi kelemahan model secara spesifik dengan data pada kondisi pencahayaan rendah.

Secara akademik, hasil pengujian menunjukkan bahwa kondisi pencahayaan memiliki pengaruh terhadap kemampuan model dalam mendeteksi dan mengklasifikasikan objek. Perubahan intensitas cahaya dapat memengaruhi kejelasan fitur visual objek, seperti bentuk, warna, dan tekstur, sehingga berdampak pada tingkat keberhasilan deteksi. Pada kondisi pencahayaan yang lebih baik, objek dapat dikenali dengan lebih jelas sehingga performa deteksi cenderung meningkat, sedangkan pencahayaan yang rendah dapat menyebabkan penurunan performa dan meningkatkan kemungkinan objek tidak terdeteksi. Oleh karena itu, kondisi pencahayaan menjadi salah satu faktor penting yang perlu diperhatikan dalam penerapan sistem deteksi objek, terutama pada lingkungan dengan intensitas cahaya yang berubah-ubah.

Tingkat Kerusakan	Precision	Recall	F1-score	Accuracy
Utuh	95.91%	94.17%	94.94%	94.17%
Rusak	81.56%	77.50%	78.85%	77.50%
Rusak Parah	72.74%	61.67%	66.45%	61.67%

Gambar 10. Hasil Pengujian Tingkat Kerusakan Objek

Di antara seluruh skenario pengujian, kondisi kerusakan objek menghasilkan degradasi performa paling drastis: akurasi turun dari 94,17% pada kondisi objek utuh, menjadi 77,5% pada kondisi rusak, dan anjlok menjadi hanya 61,67% pada kondisi rusak parah. Pola penurunan ini tidak proporsional—penurunan dari kondisi baik ke rusak jauh lebih kecil dibandingkan penurunan dari kondisi rusak ke rusak parah, menunjukkan adanya efek ambang (threshold effect) daripada penurunan yang bertahap.

Interpretasi atas pola ini adalah bahwa model bergantung secara signifikan pada bentuk global (shape) objek sebagai fitur pembeda utama antarkelas sampah. Selama kerusakan masih bersifat ringan hingga sedang, bentuk dasar objek—misalnya siluet botol atau kaleng—masih dapat dikenali. Namun ketika kerusakan menjadi parah hingga mengubah struktur objek secara fundamental (hancur, pecah, atau terdeformasi total), fitur bentuk yang menjadi acuan utama model ikut hilang, sehingga model kehilangan basis untuk membedakan satu kelas dari kelas lainnya.

Temuan ini memiliki relevansi akademik yang penting bagi riset deteksi sampah berbasis visual: sebagian besar penelitian serupa cenderung menggunakan sampel sampah dalam kondisi relatif utuh untuk pelatihan dan pengujian, padahal kondisi riil di lapangan justru didominasi oleh sampah yang telah mengalami deformasi akibat proses pembuangan, penekanan, atau pelapukan. Hasil ini menyiratkan bahwa generalisasi model deteksi sampah ke kondisi lapangan nyata memerlukan diversifikasi data latih yang secara sengaja memuat berbagai tingkat deformasi objek, bukan hanya objek dalam kondisi ideal.

Jumlah objek	Precision	Recall	F1-score	Accuracy
1 – 4 Objek	96.69%	96.67%	96.64%	96.67%
5 – 8 Objek	92.43%	91.67%	91.95%	91.67%
9 – 12 Objek	87.35%	80.83%	83.92%	80.83%

Gambar 12. Hasil Pengujian Jumlah Objek

Pengujian terhadap variasi jumlah objek dalam satu frame menunjukkan tren penurunan performa yang konsisten seiring meningkatnya kepadatan objek: akurasi 96,67% pada kuantitas 1–4 objek, menurun menjadi 91,67% pada 5–8 objek, dan menurun lebih jauh menjadi 80,83% pada 9–12 objek. Yang menarik untuk dicermati adalah bahwa peningkatan kesalahan pada skenario ini didominasi oleh meningkatnya jumlah objek yang gagal terdeteksi (missed detection) akibat saling tumpang tindih (occlusion), sementara model tetap tidak pernah menghasilkan deteksi palsu pada area yang sebenarnya kosong (tidak ada false alarm pada baris background).

Pola ini mengindikasikan bahwa model bersifat konservatif dalam mendeteksi objek—ia cenderung tidak mendeteksi ketimbang salah mendeteksi objek yang tidak ada. Pada saat yang sama, ketika objek saling bertumpuk, sebagian fitur visual objek yang berada di belakang atau tertutup objek lain hilang dari pandangan kamera, sehingga bounding box yang dihasilkan menjadi kurang presisi atau bahkan gagal terbentuk sama sekali. Ini merupakan keterbatasan yang secara luas diakui pada arsitektur detektor objek berbasis single-shot maupun anchor-based ketika dihadapkan pada skenario padat dan bertumpuk.

Secara akademik, temuan ini menggarisbawahi bahwa kapasitas model dalam menangani objek tunggal atau sedikit objek tidak dapat serta-merta diekstrapolasi untuk skenario tumpukan sampah yang padat, sebagaimana kondisi riil di tempat pembuangan akhir atau bak sampah yang jarang berisi objek dalam jumlah sedikit. Hasil ini membuka ruang penelitian lanjutan terkait optimalisasi non-maximum suppression, penyesuaian ukuran anchor box, atau penerapan arsitektur yang lebih tangguh terhadap occlusion untuk meningkatkan keandalan sistem pada kondisi kepadatan tinggi.

Jika seluruh temuan di atas dirangkai, pembahasan ini menunjukkan bahwa keandalan model deteksi sampah anorganik bukanlah nilai tunggal yang statis, melainkan sangat bergantung pada konteks: jarak pengambilan gambar, intensitas cahaya, kondisi fisik objek, dan tingkat kepadatan objek dalam frame. Model dengan konfigurasi 150 epoch memang terbukti sebagai konfigurasi paling optimal secara agregat, namun analisis mendalam mengungkap bahwa performa optimal tersebut hanya tercapai pada kondisi ideal—jarak dekat, cahaya cukup, objek utuh, dan kepadatan rendah. Begitu satu atau lebih faktor tersebut menyimpang dari kondisi ideal, terutama kerusakan objek parah dan jarak jauh, penurunan performa menjadi sangat signifikan.

Pola lintas-pengujian juga menunjukkan benang merah yang konsisten: seluruh faktor eksternal pada dasarnya bermuara pada satu mekanisme yang sama, yaitu berkurangnya kekayaan dan kejelasan fitur visual yang tersedia bagi model untuk diekstraksi—baik karena objek terlalu jauh, cahaya kurang, bentuk objek rusak, maupun tertutup objek lain. Karakteristik material yang transparan dan reflektif (botol kaca dan botol plastik) secara sistematis memperbesar kerentanan ini dibandingkan material buram (kaleng dan styrofoam).

Kontribusi akademik utama dari pembahasan ini bukan sekadar melaporkan bahwa model "bekerja dengan baik", melainkan memetakan secara eksplisit ambang batas operasional di mana keandalan model mulai menurun signifikan. Peta ambang batas ini memberikan landasan empiris bagi penelitian deteksi sampah berbasis deep learning berikutnya untuk merancang strategi pengumpulan data latih yang lebih representatif terhadap kondisi nyata, sekaligus menjadi acuan praktis bagi perancangan sistem penyortiran sampah otomatis agar parameter operasional—jarak kamera, pencahayaan, dan toleransi kepadatan objek—ditetapkan sesuai dengan batas kemampuan model yang telah teridentifikasi, alih-alih diasumsikan secara umum tanpa dasar pengujian empiris.

IV. HASIL & KESIMPULAN

Penelitian ini berhasil menjawab tujuan dan rumusan masalah yang diajukan, yaitu merancang dan mengimplementasikan sistem klasifikasi sampah anorganik berbasis YOLOv12 menggunakan bahasa pemrograman Python. Sistem yang dikembangkan terbukti mampu mendeteksi dan mengklasifikasikan empat jenis sampah anorganik, yaitu botol kaca, botol plastik, kaleng, dan styrofoam, secara real-time melalui webcam.

Dari sisi temuan utama, hasil pengujian menunjukkan bahwa performa model sangat dipengaruhi oleh jarak objek terhadap kamera: akurasi tertinggi sebesar 90,83% dicapai pada jarak 50 cm, kemudian menurun menjadi 87,50% pada jarak 100 cm, 75,00% pada jarak 200 cm, dan mencapai titik terendah 48,33% pada jarak 300 cm. Selain jarak, intensitas cahaya juga berpengaruh terhadap kemampuan model dalam mengenali objek, dengan akurasi tertinggi 87,50% pada kondisi terang (>100 lux), sedikit menurun menjadi 86,67% pada kondisi cahaya sedang (51–100 lux), dan turun menjadi 75,00% pada kondisi minim cahaya (<50 lux).

Selanjutnya, tingkat kerusakan objek juga terbukti memengaruhi akurasi deteksi secara signifikan, di mana kondisi objek yang baik/utuh menghasilkan akurasi optimal sebesar 94,17%, namun menurun menjadi 77,50% pada objek yang rusak (penyok/robek) dan turun drastis menjadi 61,67% pada objek yang rusak parah. Demikian pula, jumlah objek dalam satu citra berpengaruh terhadap performa deteksi akibat risiko objek saling menutupi, dengan akurasi tertinggi 96,67% pada kuantitas objek sedikit (1–4 objek), menurun menjadi 91,67% pada kuantitas sedang (5–8 objek), dan menjadi 80,83% pada kondisi tumpukan terbanyak (9–12 objek).

Secara praktis, temuan-temuan ini menunjukkan bahwa sistem klasifikasi berbasis YOLOv12 layak diterapkan untuk mendukung proses pemilahan sampah anorganik secara real-time, meskipun performanya bersifat kondisional terhadap faktor jarak, cahaya, kondisi fisik objek, dan kepadatan objek. Sistem ini berpotensi dikembangkan lebih lanjut dengan penambahan fitur penyimpanan data hasil deteksi untuk keperluan dokumentasi dan analisis, serta diintegrasikan dengan perangkat keras otomatis seperti robot pemilah sampah guna mendukung proses pemilahan sampah secara otomatis dan berkelanjutan.

Adapun keterbatasan penelitian ini terletak pada sensitivitas model terhadap kondisi jarak, pencahayaan, tingkat kerusakan objek, dan kepadatan objek dalam citra, serta cakupan klasifikasi yang masih terbatas pada empat jenis sampah anorganik. Oleh karena itu, penelitian selanjutnya disarankan untuk menambahkan variasi jenis sampah anorganik guna memperluas cakupan klasifikasi dan meningkatkan kemampuan generalisasi sistem, serta melakukan perbandingan performa antara metode YOLOv12 dengan metode deteksi objek lain seperti Faster R-CNN, SSD, maupun versi YOLO lainnya, untuk memperoleh gambaran yang lebih komprehensif mengenai akurasi, kecepatan, dan efisiensi metode dalam proses klasifikasi sampah anorganik secara real-time.

REFERENSI

- [1] Kementerian Lingkungan Hidup dan Kehutanan, “SIPSN - Sistem Informasi Pengelolaan Sampah Nasional,” 2024. [Daring]. Tersedia pada: <https://sipsn.menlhk.go.id>
- [2] M. R. Rahman, R. Kusumawati, dan F. Fatimah, “Deteksi Objek Menghitung Pohon Kelapa Sawit Menggunakan Metode Deep Learning,” *Bina J. Pembang. Drh.*, vol. 2, no. 1, hal. 45–51, 2023.
- [3] H. Abdillah, A. N. Syahbana, G. Ishaq, A. Husain, dan S. Agustin, “Detektif Sampah : Klasifikasi Jenis Sampah Organik dan Anorganik Menggunakan Metode YOLOv5 Berbasis Website,” vol. 3, no. 2, hal. 128–135, 2025.
- [4] P. N. Dacipta dan R. E. Putra, “Sistem Klasifikasi Limbah Menggunakan Metode Convolutional Neural Network (CNN) Pada Webservice Berbasis Framework Flask,” *J. Informatics Comput. Sci.*, vol. 3, no. 04, hal. 394–402, 2022, doi: 10.26740/jinacs.v3n04.p394-402.
- [5] T. D. Kusuma, A. D. Saputra, B. A. Arianto, N. Puspitasari, dan P. I. Surakarta, “Deteksi dan pemantauan sampah plastik di perairan menggunakan drone berbasis ai,” no. November 2024, hal. 172–178.
- [6] R. Kurniawan, P. B. Wintoro, Y. Mulyani, dan M. Komarudin, “Implementasi Arsitektur Xception Pada Model Machine Learning Klasifikasi Sampah Anorganik,” *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, hal. 233–236, 2023, doi: 10.23960/jitet.v11i2.3034.
- [7] D. H. Saputra, B. Imran, dan Juhartini, “Object Detection Untuk Mendeteksi Citra Buah-Buahan Menggunakan Metode Yolo,” *J. Kecerdasan Buatan dan Teknol. Inf.*, vol. 2, no. 2, hal. 70–80, 2023, doi: 10.69916/jkbt.v2i2.18.
- [8] P. Studi, S. Komputer, U. Pembangunan, dan P. Budi, “IMPLEMENTASI METODE YOLO PADA DETEKSI OBJEK MANUSIA,” vol. 8, no. 2, hal. 234–240, 2024.
- [9] B. Ismail Arianto dan E. Zuliarso, “Implementasi Metode YOLO pada Deteksi Pakaian Keselamatan yang Lengkap di Proyek Kontruksi,” *Ranah Res. J. Multidiscip. Res. Dev.*, vol. 6, no. 1, hal. 56–63, 2023, doi: 10.38035/rj.v6i1.795.
- [10] I. Andi, M. Muchtar, dan J. Y. Sari, “Mask Detection Using the YOLO (You Only Look Once) Method,” *J. Media Inf. Teknol.*, vol. 1, no. 1, hal. 1–12, 2024, doi: 10.69616/mit.v1i1.165.
- [11] F. Ramadhani, A. Satria, dan S. Dewi, “Identifikasi Kendaraan Bermotor pada Dashcam Mobil Menggunakan Algoritma YOLO,” *Hello World J. Ilmu Komput.*, vol. 2, no. 4, hal. 199–206, 2024, doi: 10.56211/helloworld.v2i4.466.
- [12] D. H. Kusuma dan M. Mauizah, “Deteksi Lampu Lalu Lintas Menggunakan YOLO untuk Autonomous Car,” *J. Comput. Eng. Network, Intell. Multimed.*, vol. 1, no. 1, hal. 21–27, 2023, doi: 10.59378/jcenim.v1i1.5.
- [13] D. Hafidzulrahman, “Perbandingan Algoritma You Only Look Once (YOLO) versi 5 dan versi 8 sebagai Object Detection pada Pendeteksian Hilal,” *Fakultas Sains dan Teknologi UIN Syarif Hidayatullah Jakarta*, 2023.
- [14] R. Khana, A. E. Saputra, dan M. Sobirin, “Implementasi Sistem Presensi Pada Kegiatan Seminar Dengan Pengenalan Wajah Menggunakan Metode YOLO V5,” *J. Kaji. Tek. Elektro*, vol. 9, no. 1, hal. 45–57, 2024.
- [15] G. I. Andaru, “Pengembangan Model Deteksi Untuk On-shelf Availability Produk menggunakan YOLOv12 Pada Aplikasi Bergerak,” *Universitas Islam Indonesia*, 2024.