

Implementasi Object Detection Pada Aplikasi Bank Sampah untuk Klasifikasi Jenis Sampah

1st Ahmad Syafii

Faculty of Electrical Engineering
Telkom University
Bandung, Indonesia
ahmadsyafii@student.telkomuniversity.
ac.id

2nd Sofia Naning Hertiana

Faculty of Electrical Engineering
Telkom University
Bandung, Indonesia
sofiananing@telkomuniversity.ac.id

3rd Sussi

Faculty of Electrical Engineering
Telkom University
Bandung, Indonesia
sussiss@telkomuniversity.ac.id

Abstrak — Masalah penimbunan sampah menjadi urgensi utama saat ini, data dari Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) dari Kementerian Lingkungan Hidup dan Kehutanan (KLHK) tahun 2022 menunjukkan bahwa jumlah sampah yang belum terkelola dengan baik sebesar 7,2 juta ton. Bank sampah yang menjadi solusi awal dinilai kurang optimal dalam mengatasi masalah penimbunan sampah karena masih banyak nya kekurangan dari efisiensi sistem bank sampah yang berdampak pada tingkat partisipasi masyarakat yang rendah, sehingga membutuhkan solusi dengan pendekatan teknologi yang efisien dan tepat, yaitu dengan aplikasi bank sampah. Aplikasi bank sampah dengan menggunakan model *object detection* berbasis YOLOv11n mampu menjalankan fungsi pendeteksian jenis sampah dengan akurat, ditunjukkan dari hasil mAP@50 sebesar 0,904. Hasil ini ditemukan dari proses pengujian terhadap jarak objek dan waktu deteksi. Adapun jarak optimal yang disarankan yaitu 35 cm yang didapatkan dari hasil pengujian ditemukan bahwa jarak 35 cm merupakan jarak optimal dalam hal akurasi deteksi dan kecepatan pendeteksian objek.

Kata kunci— aplikasi, implementasi, bank sampah, *object detection*

Abstract — The issue of waste accumulation is currently a major concern. Data from the National Waste Management Information System (SIPSN) of the Ministry of Environment and Forestry (KLHK) in 2022 shows that the amount of waste that has not been properly managed is 7.2 million tons. Waste banks, which were initially seen as a solution, are deemed less than optimal in addressing the waste accumulation problem due to the many shortcomings in the efficiency of the waste bank system, which has led to low levels of community participation. This necessitates a solution with an efficient and appropriate technological approach, namely a waste bank application. The waste bank application, utilizing the YOLOv11n-based object detection model, can accurately detect waste types, as evidenced by the mAP@50 result of 0.904. This result was obtained from testing the object distance and detection time. The optimal distance recommended is 35 cm, as determined by testing, which found that 35 cm is the optimal distance in terms of detection accuracy and object detection speed.

Keyword— application, implementation, waste bank, *object detection*

I. PENDAHULUAN

Masalah penimbunan sampah menjadi urgensi utama kita saat ini. Berdasarkan data dari Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) dari Kementerian Lingkungan

Hidup dan Kehutanan (KLHK) tahun 2022 menunjukkan bahwa jumlah timbunan sampah nasional mencapai 21,1 juta ton dengan 7,2 juta ton sampah yang belum terkelola dengan baik [1]. Timbunan sampah yang belum terkelola ini akan membawa berbagai dampak negatif yang merugikan dan membahayakan masyarakat, seperti terjadinya pencemaran lingkungan, seperti banjir, pencemaran udara dan pencemaran air sehingga air bersih susah untuk didapatkan [2]. Dengan meninjau dari permasalahan ini, dapat disimpulkan bahwa untuk mengatasi permasalahan ini dibutuhkan pengelolaan sampah yang baik agar dapat mengurangi timbunan sampah. Bank sampah menjadi solusi yang ditawarkan dalam mengatasi permasalahan ini, namun belum menjadi mampu menyelesaikan masalah ini, sehingga dibutuhkan pemanfaatan teknologi dalam pengelolaan bank sampah agar dapat bekerja secara efisien dan tepat.

Bank sampah adalah media untuk pengumpulan sampah yang telah disortir berdasarkan jenis nya [3]. Masyarakat diajak untuk dapat menukarkan sampah yang dimilikinya dan diberikan *reward* seperti uang sebagai apresiasi atas partisipasi dalam pensortiran dan pengelolaan sampah. Namun, situasi di lapangan menunjukkan masih rendahnya jumlah partisipasi masyarakat dalam menukarkan sampah nya. Hal ini disebabkan karena masih kurangnya ketersediaan tempat untuk melakukan aktivitas penukaran sampah sehingga masih banyak bank sampah yang tidak beroperasi dengan baik, bahkan menjadi tidak aktif [4]. Dalam menyelesaikan permasalahan ini, dibutuhkan solusi dengan pendekatan berbasis teknologi yaitu dengan membuat aplikasi bank sampah yang telah dilengkapi dengan fitur pendeteksi objek yang mampu mendeteksi bentuk jenis sampah secara langsung dan menghitung serta mengkonversi sampah tersebut menjadi harga masing-masing jenis sampah

II. KAJIAN TEORI

A. Machine Learning

Machine learning merupakan suatu cabang dari sebuah ilmu yang mengkaji secara mendalam seputar mekanisme komputer untuk belajar tanpa melakukan pemrograman secara eksplisit. *Machine learning* ini dapat melakukan suatu hal berdasarkan ide-ide yang didapatkan dari kumpulan data sebelumnya serta melakukan identifikasi terhadap pola dan membuat keputusan dengan intervensi yang minim dari manusia sebagai pengguna nya [5].

B. YOLO (You Only Look Once)

YOLO merupakan sebuah algoritma yang mampu melakukan deteksi objek secara langsung/*real-time* yang mampu melakukan identifikasi serta pengenalan objek dengan tingkat akurasi yang tinggi dengan memproses data gambar. Yolo adalah teknologi dalam pendeteksian objek yang masih dalam pengembangan dan banyak digunakan. Teknologi ini mempunyai keunikan yang menjadi daya tarik yang tinggi karena komparabilitas yang baik. Teknologi YOLO memberikan hasil performa yang baik dalam berbagai aplikasi yang berkembang saat ini, seperti pengawasan keselamatan kerja, manajemen lalu lintas dan upaya pelestarian budaya [6].

C. Roboflow

Roboflow adalah kerangka kerja dalam pengembangan *computer vision* yang berperan dalam proses pengumpulan data hingga pra pemrosesan menjadi lebih baik, serta teknik pelatihan model. Penggunaan roboflow ini digunakan untuk membagikan dataset di waktu yang bersamaan dengan pemrosesan dataset, melakukan annotate atau penandaan objek yang dideteksi dengan menggunakan bounding box. Lalu roboflow ini dapat digunakan dalam proses pre-processing pada suatu dataset seperti melakukan grayscale, dan augmentasi dengan memanfaatkan roboflow [7].

D. Confusion Matrix

Confusion matrix adalah tabel yang digunakan dalam mempresentasikan jumlah data uji yang telah diklasifikasikan dengan nilai benar dan nilai salah. Hal ini dilakukan agar memudahkan proses evaluasi akurasi dari sistem klasifikasi dan melakukan identifikasi ketika terjadi kesalahan klasifikasi [8]. Adapun gambar dari *confusion matrix* digambarkan sebagai berikut

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 1 Confusion Matrix

Confusion matrix adalah teknik yang efektif dan dinilai mudah dalam melakukan pengukuran dari kinerja atas suatu sistem klasifikasi. Dalam melakukan proses penghitungan atas *precision* dan *recall*, maka digunakan lah rumus berikut:

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

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


Pada *confusion matrix* terdapat empat elemen utama yang digunakan, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Elemen ini akan digunakan dalam penghitungan metrik evaluasi yaitu *precision* dan *recall*. *Precision* merupakan pengukuran dalam ketepatan model ketika memprediksi kelas positif, *recall* melakukan pengukuran tentang seberapa baik model dalam

mengenali data positif. Dengan penggunaan *confusion matrix*, kelebihan dan kekurangan dari suatu model dapat dipahami secara menyeluruh.

III. METODE

A. Arsitektur Sistem

Arsitektur sistem aplikasi bank sampah disusun agar mampu menjelaskan solusi yang dibuat dalam rangka pengembangan dari suatu sistem, seperti pemilihan teknologi yang akan dipakai untuk *frontend*, *backend* dan integrasi model pada *machine learning*. Gambar 2 menjelaskan diagram arsitektur sistem aplikasi sebagai berikut.



Gambar 2 Diagram Arsitektur Sistem Aplikasi

Dalam melakukan pendekatan pada *machine learning* maka digunakanlah model *object detection* YOLOv11 yang telah melewati proses pelatihan agar mampu menghasilkan performa yang optimal. Model *machine learning* ini digunakan dengan tujuan untuk menjadikan model yang mampu memproses citra sampah yang telah ditangkap oleh kamera. Adapun data yang didapatkan berupa gambar dan label yang harus disiapkan dari awal, lalu melewati tahap preprocessing yaitu resize dan augmentation, sehingga fitur yang telah melalui proses ekstraksi dengan pemanfaatan arsitektur YOLOv11 dan telah melalui proses pelatihan model klasifikasi citra ini mampu mencapai tujuan yaitu menghasilkan model deteksi sampah yang berperforma akurat dan tepat.

B. Pengumpulan Dataset dan Anotasi Data

Metode pengumpulan data ini memanfaatkan sumber dan variasi. Data yang telah terkumpul ini didapatkan dari database publik. Lalu, dilakukan pengambilan foto secara mandiri di berbagai kondisi lingkungan dengan tujuan untuk mengumpulkan variasi yang lebih beragam. Setelah itu, dilakukan anotasi data.

Proses anotasi data ini dilakukan dengan melakukan penambahan label kelas ke gambar yang telah berhasil dikumpulkan agar selanjutnya akan diidentifikasi kelas jenis sampah yang dapat disetorkan ke bank sampah. Tabel 1 di bawah ini memaparkan anotasi data kelas yang digunakan sebagai berikut:

Tabel 1 Class berdasarkan banyaknya jenis sampah

No	Class
1	Botol Plastik

2	Gelas Plastik
3	Kantong Plastik
4	Kemasan Kaleng
5	Kemasan Plastik
6	Apel
7	Jeruk
8	Pisang
9	Wortel
10	Sayuran

Berdasarkan tabel 1, terdapat 10 kelas sampah yang telah diidentifikasi, mulai dari botol plastik sebagai sampah anorganik, hingga sampah organik seperti sayuran. Tujuan dilakukan nya proses identifikasi jenis sampah sebelum melakukan proses anotasi ini yaitu agar dapat mengurangi kesalahan dalam proses pelabelan sehingga mampu meningkatkan tingkat akurasi dari dataset.

C. Pembagian Data

Dalam proses pembagian data 70:20:10 ini mengacu pada langkah-langkah yang diperlukan dataset dalam tahapan pelatihan, validasi, dan pengujian model. Dapat dijelaskan bahwa nilai 70% digunakan untuk *training* atau untuk melatih model. Dataset akan mempelajari data dengan melakukan *update* terhadap bobot selama proses *training*. Nilai 20% ini sebagai *validation* atau data akan digunakan selama proses pelatihan dalam rangka evaluasi atas kinerja dari model dan untuk menghindari terjadinya *overfitting*. *Validation set* ini membantu hyper parameter yang terbaik dan melakukan *monitoring* terhadap model dalam generalisasi apakah beroperasi dengan baik. Lalu nilai 10% ini untuk *testing* atau menjelaskan setelah proses pelatihan berakhir, *testing set* ini dipakai untuk evaluasi akhir atas kinerja dari model diatas yang benar-benar baru, atau belum pernah dideteksi oleh model [9]. Berikut ini tabel informasi pembagian data dataset dijelaskan secara detail pada Tabel 2

Tabel 2 Pembagian Data Dataset

set	Presentase	Jumlah gambar
train	70%	3989
valid	20%	1139
test	10%	569

D. Instalasi Library

Instalasi *library* menjadi penting untuk dilakukan agar proses pengembangan model YOLOv11n dapat berlangsung dengan baik. *Library* ini berperan dalam fungsionalitas inti untuk proses membangun, pelatihan, dan evaluasi dari model YOLOv11n. Pada tabel 3 ini secara rinci menjelaskan daftar *library* yang dipakai yaitu sebagai berikut:

Tabel 3 Daftar Library

Library	Deskripsi
ultralytics	Untuk menyediakan antarmuka yang akan digunakan dalam proses pelatihan, validasi, deteksi objek dan ekspor model.
opencv-python	Digunakan dalam proses pembacaan, penampilan, dan pemodifikasian gambar atau frame sebagai input model.

matplotlib	Digunakan untuk visualisasi data dan hasil pelatihan model, seperti grafik akurasi, loss function, serta bounding box hasil deteksi.
pandas	Digunakan untuk mengelola data dalam bentuk tabel, berguna untuk membaca, membersihkan, dan memproses data hasil pelatihan atau deteksi objek.
PyYAML	Digunakan untuk membaca dan menulis file konfigurasi dalam format YAML, misalnya seperti file konfigurasi dataset dan parameter pelatihan.

E. Inisiasi Hyperparameter

Hyperparameter merupakan sebuah variabel yang memiliki nilai dalam mengontrol dari proses *training* dan untuk menentukan nilai parameter model. *Hyperparameter* ini adalah salah satu faktor penting dalam mempengaruhi kinerja atas model yang dibuat agar memiliki tingkat performa yang tinggi. *Hyperparameter* ini didapatkan dari proses inisiasi secara manual sebelum dilakukan nya proses *training*. *Hyperparameter* ini bisa didapatkan pada YOLOv11n yang digunakan [10]. Tabel 4 dibawah ini akan menjelaskan secara mendetail terkait konfigurasi *hyperparameter* pada YOLOv11n yang bisa dicek pada tabel berikut:

Tabel 4 Konfigurasi Hyperparameter YOLOv11n

Hyperparameter	Value	Penjelasan
Lr0	0.01	Kecepatan awal model dalam belajar dari data.
Lrf	0.01	Tingkat pembelajaran di akhir training.
epochs	60	Jumlah iterasi dimana seluruh dataset dilatih
batch	16	Jumlah sampel yang diproses sebelum pembaruan bobot.

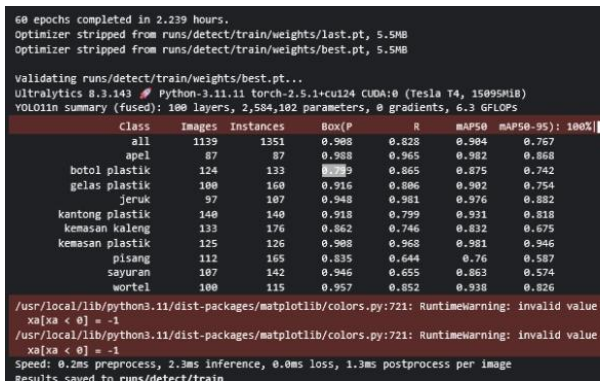
IV. HASIL DAN PEMBAHASAN

Pada bagian ini akan menjelaskan terkait pengembangan model *machine learning* dalam aplikasi bank sampah yang berfokus pada penerapan *object detection* dalam pengidentifikasian jenis-jenis sampah secara otomatis dengan memanfaatkan kamera perangkat pengguna. Teknologi ini berperan dalam meningkatkan efisiensi dari proses penyortiran sampah, namun tetap memperhitungkan tingkat akurasi dalam klasifikasi jenis sampah dan mengkonversi perhitungan nilai sampah menjadi harga secara *real-time*. Bagian-bagian yang tergabung dalam model ini dirancang dengan tujuan agar mampu beroperasi secara cepat dan responsif, mampu memenuhi kebutuhan pengguna dalam lingkup aplikasi *mobile* yang dinamis.

A. Hasil Pelatihan Hyperparameter YOLOv11n

Dalam rangka mencari model YOLOv11n yang memiliki tingkat kinerja yang baik, maka dilakukan lah eksperimen

pelatihan dengan jumlah epoch. Pada eksperimen ini digunakan epoch, batch size 16, lr0 dan lrf sebesar 0.01, yang ditampilkan pada gambar 3 dibawah ini.



Gambar 3 Hasil Training YOLOv11n

Berdasarkan hasil eksperimen pelatihan model YOLOv11n menghasilkan performa *object detection* yang sangat baik, dengan nilai mAP mencapai 0.904. Hasil ini menunjukkan bahwa model eksperimen mencapai rata-rata presisi 90.4% dalam pendeteksian objek dengan tingkat keyakinan diatas 50%

B. Pengujian Deteksi Berdasarkan Jarak dan Kecepatan

Pada penelitian ini dilakukan pengujian terhadap kinerja dari *object detection* pada aplikasi bank sampah dengan memanfaatkan masing-masing 100 gambar dari lima jarak yang berbeda, dari 15 sampai 55 cm. Hal ini bertujuan untuk menganalisis pengaruh jarak kamera terhadap performa kecepatan dan akurasi dari deteksi objek. Adapun hasil percobaan digambarkan dalam grafik perbandingan kecepatan terhadap jarak pada gambar 4 dibawah ini:



Gambar 4 Grafik Perbandingan Kecepatan Terhadap Jarak

Gambar 4 menunjukkan bahwa terdapat hubungan yang terbalik antara jarak objek dan waktu deteksi. Ditemukan bahwa semakin jauh jarak objek dari kamera yaitu 15 sampai 55 cm, maka waktu deteksi menjadi cenderung cepat, yaitu dari 8805 ms menjadi 6797 ms. Pada grafik juga ditunjukkan penurunan waktu deteksi yang signifikan pada jarak 15 cm sampai 35 cm, selebihnya cenderung stabil, sehingga jarak optimal yang disarankan adalah 35 cm. Hal ini disebabkan karena pada jarak tersebut menampilkan hasil keseimbangan yang terbaik antara kecepatan dan akurasi. Hasil temuan ini menjadi penting bagi proses pengembangan aplikasi bank sampah yang menekankan pada proses pendeteksian yang cepat dan tepat dalam kondisi nyata di lapangan.

V. KESIMPULAN

Pada penelitian ini menampilkan bahwa dalam penerapan model *object detection* berbasis YOLOv11n pada aplikasi bank sampah mampu menjalankan pendeteksian jenis sampah secara efisien dn akurat. Sistem yang telah dibangun dapat melakukan identifikasi objek secara *real-time* serta mampu menghitung total nilai sampah dan mengkonversikan total tersebut menjadi harga berdasarkan jenis sampah yang terdeteksi. Meninjau dari hasil pengujian model, ditemukan model mampu mencapai nilai mAP@50 sebesar 0,904. Hasil ini menunjukkan tingkat akurasi deteksi yang sangat baik dalam hal pengenalan objek sampah pada berbagai macam kondisi pencahayaan maupun jarak.

Model yang telah terintegrasi secara optimal dengan *backend* sistem, menjadikan hasil deteksi dengan waktu respons yang cepat dan konsisten. Implementasi dari arsitektur REST API mendukung proses integrasi aplikasi *mobile* agar mampu merespons inputan pengguna secara *real-time*. Hasil pengujian menampilkan bahwa sistem dapat memberikan hasil deteksi yang cepat dan akurat, baik melalui simulasi maupun penggunaan langsung di kehidupan sehari-hari.

REFERENSI

[1] P. Kemenko, “7,2 Juta Ton/7,2 Juta Ton Sampah di Indonesia Belum Terkelola Dengan Baik,” Kementerian Koordinator Bidang Pembangunan Manusia dan Kebudayaan Republik Indonesia. Accessed: Sep. 29, 2024. [Online]. Available: <https://www.kemenkopmk.go.id/72-juta-ton-sampah-di-indonesia-belum-terkelola-dengan-baik>

[2] P. Saptomo, “Dampak Tempat Pembuangan Dan Penampungan Sampah Akhir (Tpa) Terhadap Lingkungan Masyarakat Sekitar,” vol. 7 nomor 2, pp. 5717–5722, 2024.

[3] D. Ariefahnoor, N. Hasanah, and A. Surya, “Pengelolaan Sampah Desa Gudang Tengah Melalui Manajemen Bank Sampah,” *Jurnal Kacapuri : Jurnal Keilmuan Teknik Sipil*, vol. 3, no. 1, p. 14, 2020, doi: 10.31602/jk.v3i1.3594.

[4] Administrator, “Kurangi Sampah di TPA, Bank Sampah Diharapkan Semakin Banyak,” Citarum Harum Juara. Accessed: Oct. 08, 2024. [Online]. Available: <https://citarumharum.jabarprov.go.id/kurangi-sampah-di-tpa-bank-sampah-diharapkan-semakin-banyak/>

[5] A. Wijoyo, A. Yudistira Saputra, S. Ristanti, and S. Rafly Sya’Ban, “Pembelajaran Machine Learning,” *OKTAL (Jurnal Ilmu Komputer dan Science)*, vol. 3, no. 2, pp. 375–380, 2024, [Online]. Available: <https://journal.mediapublikasi.id/index.php/oktal/article/view/2305>

[6] M. Febri Yudhi, N. Erzed, Yulhendri, and J. Sunupurwa Asri, “IMPLEMENTASI PERBANDINGAN YOLO V8 DAN YOLO V11 DALAM PENERAPAN TATA TERTIB BERPAKAIAN DI LINGKUNGAN KAMPUS STUDI KASUS UNIVERSITAS ESA UNGGUL KAMPUS BEKASI Muhammad,” *Kohesi: Jurnal Multidisiplin Saintek*, vol. 7, no. 3, pp. 1–23, 2025.

- [7] N. J. Hayati, D. Singasatia, and M. R. Muttaqin, "Object Tracking Menggunakan Algoritma You Only Look Once (YOLO)v8 untuk Menghitung Kendaraan," *Komputa : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 2, pp. 91–99, 2023, doi: 10.34010/komputa.v12i2.10654.
- [8] R. Nurhidayat and K. E. Dewi, "Penerapan Algoritma K-Nearest Neighbor Dan Fitur Ekstraksi N-Gram Dalam Analisis Sentimen Berbasis Aspek," *Komputa : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 1, pp. 91–100, 2023, doi: 10.34010/komputa.v12i1.9458.
- [9] S. Muhartini, A. Sunyoto, and A. Hendi Muhammad, "Implementasi Metode Deep Learning CNN Dalam Klasifikasi Tajong (Sarung) Samarinda," *Jurnal SENOPATI*, vol. 6, no. 1, pp. 28–41, 2024.
- [10] N. M. HARIS, "Implementasi Algoritma YOLOv7 Pada Sistem Penghitung Benih Kelapa Sawit Secara Realtime," Skripsi, Universitas Hasanuddin, 2023. [Online]. Available: <https://repository.unhas.ac.id/id/eprint/30580/>

