

YOLOv8n untuk Deteksi Sampah secara Real-Time pada Aplikasi Bank Sampah

1st Yulintyandra Puja Antanita
*Telecommunication Engineering,
 School of Electrical Engineering
 Telkom University
 Bandung , Indonesia*
 yulintyandra@student.telkomuniversity.ac.id

4th Yugo Pratama
*Telecommunication Engineering,
 School of Electrical Engineering
 Telkom University
 Bandung , Indonesia*
 yugoprata
 @student.telkomuniversity.ac.id

2nd Arfio Ardana
*Telecommunication Engineering,
 School of Electrical Engineering
 Telkom University
 Bandung , Indonesia*
 arfioardana@student.telkomuniversity.ac.id

5th Rita Purnamasari
*Telecommunication Engineering,
 Faculty of Electrical Engineering
 Telkom University
 Bandung, Indonesia*
 ritapurnamasari@telkomuniversity.ac.id

3rd Khoerunnisa Alfin
*Telecommunication Engineering,
 School of Electrical Engineering
 Telkom University
 Bandung , Indonesia*
 khoerunisaalfin@student.telkomuniversity.ac.id

6th Khaerudin Saleh
*Telecommunication Engineering,
 Faculty of Electrical Engineering
 Telkom University
 Bandung, Indonesia*
 khaerudin@telkomuniversity.ac.id

Abstract — Pengelolaan sampah merupakan tantangan lingkungan yang signifikan di Indonesia, terutama di kawasan perkotaan dengan tingkat kesadaran pemilahan sampah yang masih rendah. Program bank sampah yang diatur dalam Peraturan Menteri Negara Lingkungan Hidup Republik Indonesia Nomor 13 Tahun 2012 bertujuan untuk mendorong partisipasi masyarakat dalam pengelolaan sampah berbasis komunitas, namun pelaksanaannya masih belum optimal akibat keterbatasan teknologi dan proses administrasi yang masih manual. Penelitian ini mengusulkan pengembangan aplikasi bank sampah berbasis mobile yang mengintegrasikan model YOLOv8n untuk deteksi jenis sampah secara real-time. Dataset terdiri dari sembilan kategori sampah dengan total 4.500 gambar, yang dianotasi dan dibagi menjadi data latih, validasi, dan uji dengan rasio 80:10:10. Model YOLOv8n dilatih menggunakan konfigurasi 70 epoch, learning rate 0,001, dan optimizer AdamW, menghasilkan performa mAP@0.5 sebesar 0,995 dan mAP@0.5:0.95 sebesar 0,785. Pengujian lanjutan menunjukkan kemampuan generalisasi yang baik terhadap variasi bentuk, latar belakang, jarak, dan skenario multi-objek, meskipun performa menurun pada bentuk dan warna yang jarang muncul dalam dataset serta pada deteksi jarak jauh. Hasil penelitian membuktikan bahwa YOLOv8n memiliki potensi tinggi untuk diimplementasikan dalam sistem bank sampah berbasis mobile guna meningkatkan efisiensi pemilahan dan partisipasi masyarakat..

Keywords— Objek Deteksi, YOLOv8n, Computer Vision, Machine learning

I. PENDAHULUAN

Pengelolaan sampah merupakan menjadi salah satu tantangan lingkungan yang signifikan di Indonesia, khususnya di kawasan kota-kota besar [1]. Tantangan ini berasal dari masyarakat yang masih belum memiliki kesadaran dalam memilah sampah, sehingga menyebabkan sampah menjadi tercampur dan tidak dapat diolah dengan efisien [2]. Menurut data Kementerian Lingkungan Hidup dan Kehutanan Republik Indonesia (KLHK RI), timbulan sampah nasional pada tahun 2022 mencapai 68,7 juta ton per tahun dengan 41,27% di antaranya merupakan sampah organik [3].

Peraturan Menteri Negara Lingkungan Hidup Republik Indonesia Nomor 13 Tahun 2012 dibuat dengan tujuan untuk mendorong partisipasi masyarakat dalam mengelola sampah melalui pendekatan berbasis komunitas, yaitu dengan program bank sampah. Bank sampah merupakan sistem pengelolaan sampah berbasis masyarakat dimana sampah yang memiliki nilai jual dikumpulkan untuk ditukar dengan insentif berbentuk uang dengan sampah yang dapat ditukarkan merupakan sampah yang telah dipilah. Akan tetapi, program bank sampah masih belum optimal, mengingat rendahnya partisipasi masyarakat dan terbatasnya akses terhadap teknologi pengelolaan sampah yang efisien. Penelitian ini bertujuan untuk melakukan automasi administrasi pengumpulan sampah pada bank sampah untuk memudahkan pengguna [4].

Perkembangan teknologi *machine learning* dan *computer vision* membuka peluang untuk melakukan otomatisasi proses pemilahan sampah dengan teknik objek deteksi [5]. Salah satu algoritma deteksi objek yang populer adalah YOLO (*You Only Look Once*), khususnya varian YOLOv8[6]. Dengan melakukan integrasi YOLOv8 pada aplikasi bank sampah, proses klasifikasi sampah dapat dilakukan secara *real-time*, cepat, dan akurat. Penelitian ini bertujuan untuk mengembangkan aplikasi perangkat lunak bank sampah yang dapat melakukan deteksi jenis sampah secara otomatis, untuk meningkatkan efisiensi dan mengurangi kesalahan pemilahan. Dengan adanya kemudahan fitur tersebut, diharapkan masyarakat dapat antusias berpartisipasi untuk mengolah sampah.

II. KAJIAN TEORI

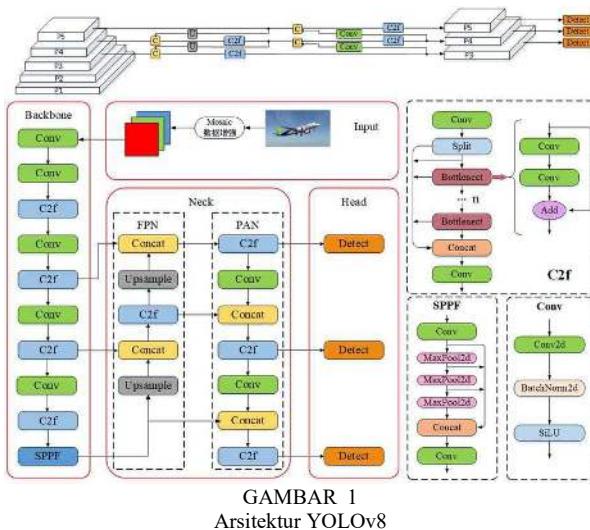
A. Bank Sampah

Mekanisme kerja bank sampah konvensional melibatkan proses seperti pemilahan sampah yang dilakukan oleh masyarakat sebelum disetorkan ke bank sampah. Namun, proses pemilahan sering kali menjadi tantangan di karenakan memerlukan pengetahuan spesifik tentang jenis sampah dan berpotensi menyebabkan kesalahan klasifikasi. Integrasi pengolahan citra berbasis machine learning ke dalam sistem bank sampah digital dapat membantu mengatasi tantangan

tersebut. Penggunaan arsitektur YOLOv8 untuk model object detection, aplikasi dapat secara otomatis mengidentifikasi jenis sampah berdasarkan citra yang diambil oleh kamera pengguna.

B. Deteksi Objek dengan YOLOv8

Dalam klasifikasi objek, selain menggunakan CNN atau *deep learning*, terdapat berbagai metode *machine learning* yang telah digunakan, seperti *K-Nearest Neighbor* (KNN)[7], *Support Vector Machine* (SVM) [8], dan *Local Binary Pattern* (LBP) [9]. Namun, metode-metode tersebut umumnya memiliki keterbatasan dalam mendekripsi objek secara real-time dan menangani variasi kondisi di lapangan. Untuk mengatasi keterbatasan tersebut, digunakan pendekatan berbasis *deep learning* seperti YOLO (*You Only Look Once*), dengan salah satu variannya yaitu YOLOv8 yang merupakan versi resmi dari Ultralytics. YOLOv8 menyediakan arsitektur ringan seperti YOLOv8n (*nano*) yang sangat cocok untuk diintegrasikan pada aplikasi mobile berbasis Flutter.



Pemilihan YOLOv8 digunakan oleh penulis, dikarenakan ketika pemilihan model, YOLOv8 merupakan model yang paling stabil dengan akurasi tinggi dan kemudahan *export* model. Arsitektur YOLOv8 dirancang dengan struktur modular dan efisien, terdiri dari beberapa komponen utama seperti *Backbone*, *Neck*, dan *Head* ditunjukkan pada Gambar 1.

III. METODE

A. Dataset dan Pra-Pemrosesan

Pengumpulan dataset menggunakan metode primer dan sekunder. Metode primer dilakukan dengan mengambil foto berbagai jenis sampah secara langsung dengan lokasi dan sudut pandang yang beragam sebanyak 4.458 gambar, sedangkan metode sekunder dilakukan dengan mengambil gambar dari internet sebanyak 42 gambar. Untuk memastikan keragaman data, dataset yang digunakan memiliki jumlah gambar yang sama untuk setiap jenis sampah yang diterima oleh bank sampah. Kategori sampah meliputi botol plastik berwarna, aluminium, botol kaca, galon, tutup botol, botol plastik transparan, kardus, plastik kemasan, dan sisa makanan.

Selanjutnya adalah proses anotasi data yang dilakukan menggunakan *platform* RoboFlow karena kemampuannya menangani *dataset* besar dan mendukung pelabelan sesuai kategori yang telah ditentukan. Dataset dibagi menjadi tiga bagian utama, yaitu *train set*, *validation set*, dan *test set* dengan rasio 80:10:10.

B. Arsitektur YOLOv8n

Model YOLOv8n digunakan karena memiliki ukuran parameter yang kecil dan kecepatan inferensi yang tinggi sehingga cocok untuk diintegrasikan pada perangkat lunak. Backbone berfungsi untuk ekstraksi fitur dengan model Conv dan C2f, neck merupakan jembatan dari backbone dan head yang menggabungkan informasi dari berbagai skala, serta head merupakan hasil output dari model berbentuk prediksi bounding box dan confidence score. Model yang digunakan adalah model YOLOv8n yang telah memiliki 3.157.200 parameter dan 129 lapisan dengan 8.9 GFLOPS yang dibutuhkan untuk inferensi.

C. Pelatihan Model

Dalam pelatihan model, digunakan perbandingan arsitektur YOLOv8n untuk mengevaluasi pengaruh perubahan struktur model terhadap performa sistem secara keseluruhan. Pada penelitian ini, performa arsitektur dasar YOLOv8n dibandingkan dengan versi modifikasi YOLOv8n-CBAM untuk menganalisis peningkatan akurasi deteksi objek [10]. Modul CBAM disisipkan sebelum proses *upsampling* pada masing-masing skala fitur. Pendekatan ini memungkinkan analisis komparatif yang lebih dalam terkait dampak arsitektur terhadap kualitas deteksi.

D. Model Evaluation

Dalam pelatihan model, digunakan perbandingan arsitektur YOLOv8n untuk mengevaluasi pengaruh perubahan struktur model terhadap performa sistem secara keseluruhan. Pada penelitian ini, performa arsitektur dasar YOLOv8n dibandingkan dengan versi modifikasi YOLOv8n-CBAM untuk menganalisis peningkatan akurasi deteksi objek.

TABEL 1
Perbandingan Pelatihan Model

Arsitektur	Epoch	mAP@0.5	mAP@0.5:0.95	Rata-rata Recall
YOLOv8n-CBAM	93	0.992	0.746	0.971
YOLOv8n	61	0.995	0.779	0.997
Konfigurasi Hyperparameter				
lr0 = 0.001 lrf = 0.01 momentum = 0.937 batch = 16				

Modul CBAM disisipkan sebelum proses *upsampling* pada masing-masing skala fitur. Pendekatan ini memungkinkan analisis komparatif yang lebih dalam terkait dampak arsitektur terhadap kualitas deteksi. Untuk menilai seberapa baik YOLOv8 dalam mendekripsi objek, digunakan tiga metrik utama, yaitu precision, recall, dan Mean Average Precision (mAP). Penilaian dilakukan dengan menetapkan ambang batas Intersection over Union (IoU), yaitu sebesar 0,5 (mAP @0.5) untuk pengukuran standar dan rata-rata dari IoU 0,5 hingga 0,95 (mAP@0.5:0.95) untuk pengukuran yang lebih menyeluruh ditunjukkan oleh Tabel x.x.

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

Persamaan 1 merupakan rumus presisi dengan TP, FP merupakan jumlah prediksi yang benar, dan jumlah prediksi yang salah.

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

Persamaan 2 digunakan untuk menghitung recall TP, FN merupakan recall, jumlah prediksi yang benar, dan jumlah objek yang sebenarnya ada tetapi tidak terdeteksi oleh model.

$$mAP@\alpha = \frac{1}{n} \sum_{i=0}^n AP_i \quad (3)$$

Persamaan 3 merupakan rumus mAP dengan $mAP@\alpha$, n, AP_i merupakan Mean Average Precision pada ambang batas IoU tertentu yang dinyatakan sebagai α dengan nilai 50 sampai 95, merepresentasikan jumlah kelas yang ada di dalam dataset, average precision untuk kelas ke-i, indeks yang menunjukkan urutan kelas dalam dataset dimulai dari 0.

IV. IMPLEMENTASI

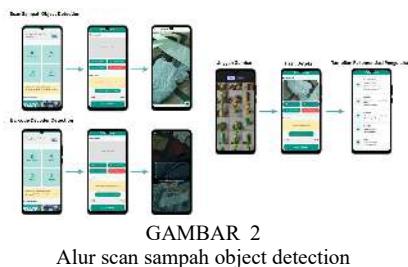
A. Lingkungan Pengembangan

Pengembangan model YOLOv8n, memerlukan sejumlah library untuk menyediakan fungsionalitas yang mendukung proses pembangunan, pelatihan, dan evaluasi model secara menyeluruh. Library tersebut mencakup berbagai modul yang digunakan untuk pemrosesan citra, augmentasi data, pelatihan model, serta visualisasi hasil. Library yang digunakan meliputi: ultralytics, torch, numpy, opencv-python, matplotlib.pyplot, matplotlib.patches, dan pandas.

B. Integrasi Model YOLOv8n

Model YOLOv8n yang telah dilatih dan menghasilkan kinerja terbaik dalam format .pt diubah menjadi format .tflite menggunakan exporter bawaan Ultralytics. Konversi ini dilakukan agar model dapat diintegrasikan secara langsung pada aplikasi mobile tanpa memerlukan server eksternal. Proses integrasi dimulai dengan menyimpan model berbentuk tflite di dalam aplikasi. Selanjutnya adalah memanggil model melalui interpretes TensorFlow Lite pada aplikasi serta mengatur pipeline pengolahan citra yang mencakup image resizing, normalisasi, dan konversi ke tensor sebelum diproses oleh model.

C. Antarmuka Pengguna



Gambar 2 di atas memperlihatkan alur fitur scan sampah dengan object detection pada aplikasi Resik. Pengguna memulai dari halaman dashboard lalu memilih menu setor

sampah. Selanjutnya, pengguna memilih metode deteksi dengan kamera, lalu diarahkan ke tampilan live kamera untuk memindai jenis sampah secara otomatis menggunakan teknologi object detection. Setelah proses pemindai selesai, aplikasi akan menampilkan hasil klasifikasi jenis sampah beserta tombol untuk melihat rekomendasi pengolahan yang sesuai.

V. PENGUJIAN

A. Performa Model Deteksi Objek

Model YOLOv8n dengan konfigurasi 70 epoch, learning rate 0.001, dan optimizer AdamW terpilih sebagai model terbaik berdasarkan perbandingan performa dengan variasi arsitektur dan optimasi lainnya terbukti pada Tabel 2. Model menunjukkan performa deteksi objek yang sangat baik mAP@0.5 sebesar 0.995 dan mAP@0.5:0.95 sebesar 0.785.

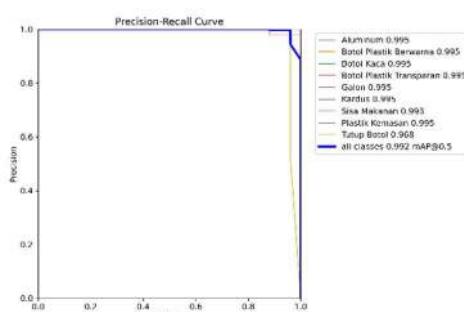
TABEL 2 Perbandingan Model Hyperparameter				
Arsitektur	Epoch	mAP@0.5	mAP@0.5:0.95	Rata-rata Recall
RMSProp	61	0.995	0.779	0.997
SGD	33	0.994	0.74	0.979
AdamW	70	0.995	0.785	0.99
Konfigurasi Hyperparameter				
lr0 = 0.001 lrf = 0.01 momentum = 0.937 batch = 16				

Untuk memudahkan integrasi pada mobile, format model yang sebelumnya ‘best.pt’ diubah menjadi TFLite yaitu ‘best.tflite’. Proses pengujian model (testing) dilakukan untuk mengukur kinerja model secara komprehensif dan memastikan bahwa model mampu melakukan generalisasi dengan baik pada gambar baru.



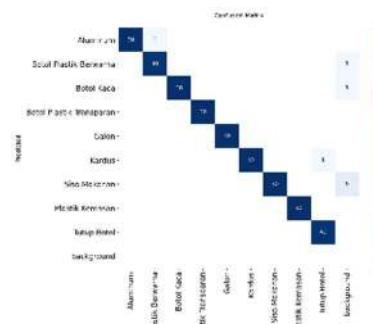
GAMBAR 3
Hasil pengujian model Yolov8-n pada dataset acak

Gambar 3 merupakan hasil uji model deteksi objek YOLOv8n yang telah dilatih untuk mengenali sembilan jenis sampah. Proses pengujian dilakukan dengan mengambil 10 gambar dari tiap kelas pada dataset secara acak. Model kemudian akan melakukan prediksi pada setiap gambar dan hasilnya dalam bentuk kotak pembatas, label, dan confidence score.



GAMBAR 4
Grafik Presisi Recall YOLOv8n

Berdasarkan grafik PR *curve* pada Gambar 4, hampir semua kelas memiliki kurva yang mendekati sudut kanan atas, menandakan kombinasi presisi dan *recall* yang tinggi. Selain itu, *confusion matrix* secara umum menunjukkan distribusi prediksi yang akurat dengan hanya sedikit *missclassifications* pada beberapa kelas.

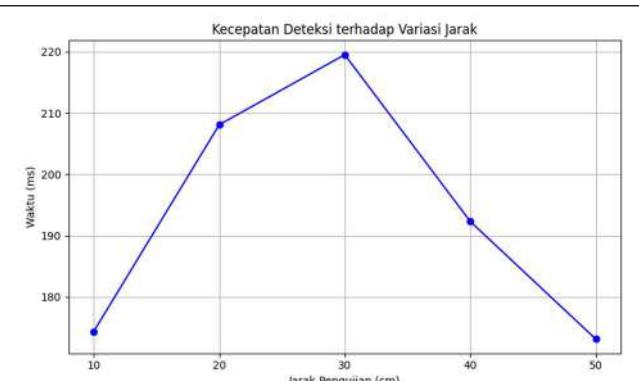


GAMBAR 5
YOLOv8n *confusion* matriks

Confusion matrix pada Gambar 5 menunjukkan jumlah prediksi benar yang meningkat, terutama pada kelas ‘Tutup Botol’, dengan kesalahan klasifikasi berhasil dikurangi menjadi 2 instance. Dengan demikian, dapat disimpulkan bahwa arsitektur YOLOv8n standar memberikan akurasi yang sedikit lebih tinggi dan kesalahan klasifikasi yang lebih sedikit.

B. Pengujian Model Deteksi Objek

Selain pengecekan performa model, dilakukan pula serangkaian pengujian tambahan untuk mengevaluasi performa model pada berbagai kondisi di dunia nyata. Pengujian tersebut meliputi variasi bentuk objek dalam setiap kelas untuk mengukur kemampuan model dalam mengenali objek yang berasal dari kelas yang sama namun memiliki perbedaan bentuk fisik. Selanjutnya, dilakukan pengujian terhadap perbedaan warna latar belakang guna mengevaluasi kinerja model ketika menghadapi variasi kontras dan dominasi warna. Pengaruh jarak antara kamera dan objek juga diuji untuk menentukan jarak optimal yang menghasilkan keseimbangan terbaik antara kecepatan dan akurasi deteksi. Terakhir, kemampuan model untuk melakukan multi-detect turut dievaluasi guna memastikan model mampu mengidentifikasi lebih dari satu objek dalam satu citra secara bersamaan.



GAMBAR 6
Grafik pengaruh variasi jarak terhadap kecepatan deteksi

Grafik yang disajikan pada Gambar 6 menunjukkan hubungan antara waktu deteksi objek (dalam milidetik) dengan jarak pengukuran (dalam sentimeter). Dari grafik tersebut, dapat dilihat bahwa kecepatan deteksi meningkat dari 10 cm ke 30 cm, dengan puncak performa pada 30 cm. Setelah jarak 30 cm, terdapat penurunan drastis dari 40 cm hingga 50 cm dikarenakan terdapat kegagalan deteksi. Pada 40 cm terdapat 1 objek yang gagal terdeteksi dan pada 50 cm terdapat 2 objek yang tidak dapat terdeteksi. Penurunan ini menunjukkan adanya batas efektif deteksi model terhadap objek pada jarak jauh yang bisa disebabkan oleh resolusi objek yang terlalu kecil dan adanya penurunan kejelasan fitur visual. Untuk kinerja deteksi model yang optimum, penulis merekomendasikan pengambilan gambar pada jarak 30 cm.

Hasil pengujian object detection terhadap variasi bentuk pada setiap kelas menunjukkan beberapa temuan penting terkait limitasi model. Model menunjukkan kemampuan deteksi yang baik pada kategori sisa makanan seperti roti, nasi, masakan, kulit pisang, dan daun-daunan, mencerminkan fleksibilitas terhadap variasi visual. Pada botol plastik berwarna, model mengenali bentuk umum seperti botol sabun dan hand cream, namun kesulitan dengan bentuk oval atau sprayer. Untuk plastik transparan, deteksi tetap akurat meskipun objek diremas. Kategori kardus dan botol kaca silinder juga terdeteksi baik, meskipun model kesulitan mengenali botol kaca transparan dan parfum kotak. Pada aluminium, kaleng dan tabung berhasil dikenali, namun aluminium foil belum terdeteksi. Tutup botol dan galon dikenali dari berbagai sudut, sedangkan plastik kemasan kerap salah klasifikasi, khususnya pada warna kuning dan putih yang sering terbaca sebagai kardus. Temuan ini mengindikasikan bahwa kemampuan generalisasi model terhadap bentuk yang tidak dominan dalam dataset masih terbatas, sehingga perlu peningkatan melalui pelatihan lanjutan dengan data yang lebih beragam.

Hasil pengujian object detection terhadap variasi latar belakang pada setiap kelas menunjukkan bahwa performa model bervariasi antar kategori objek. Plastik kemasan dan kardus mengalami penurunan akurasi pada latar coklat dan kompleks, dengan beberapa kesalahan klasifikasi. Botol plastik berwarna sulit terdeteksi pada latar hitam dan gagal sepenuhnya pada latar kompleks, sementara botol kaca mengalami salah klasifikasi pada latar hitam. Aluminium tidak terdeteksi pada latar abu-abu. Sebaliknya, botol plastik transparan, tutup botol, galon, dan sisa makanan terdeteksi secara konsisten pada kelima variasi latar, menunjukkan ketahanan model terhadap perubahan latar pada kategori tertentu.

Disarankan kepada pengguna aplikasi resik untuk melakukan object detection pada latar belakang dengan satu warna yang kontras terhadap objek, guna meningkatkan akurasi deteksi.

Pengujian kemampuan multi-detect menunjukkan bahwa performa model masih terbatas dalam mendeteksi banyak objek dalam satu gambar. Model hanya mampu mendeteksi maksimal tiga objek, dengan hasil deteksi yang akurat umumnya terbatas pada dua objek. Deteksi juga cenderung didominasi oleh kelas kardus, botol kaca, dan galon. Hal ini disebabkan oleh karakteristik pada dataset, di mana ketiga kelas tersebut memiliki ukuran dan warna yang lebih konsisten dibandingkan kelas lainnya. Konsistensi visual ini mempermudah model dalam mengenali pola, sementara objek dengan variasi bentuk dan warna yang lebih tinggi cenderung terlewat dalam skenario multi-objek. Temuan ini mengindikasikan perlunya penambahan data untuk meningkatkan generalisasi model dalam mendeteksi banyak objek sekaligus.

VI. KESIMPULAN

Berdasarkan pengujian, model YOLOv8n dengan konfigurasi 70 epoch, learning rate 0,001, dan optimizer AdamW menunjukkan kinerja deteksi terbaik dengan mAP@0.5 sebesar 0,995 dan mAP@0.5:0.95 sebesar 0,785, mencerminkan kombinasi presisi dan recall yang tinggi. Model mampu melakukan generalisasi dengan baik terhadap variasi bentuk, latar belakang, jarak, dan skenario multi-objek, meskipun performa menurun pada bentuk atau warna yang jarang muncul dalam dataset serta pada deteksi jarak jauh.

Kinerja optimal dicapai pada jarak 30 cm, dengan kemampuan mendeteksi hingga tiga objek, terutama pada kelas dengan ciri visual yang konsisten. Secara keseluruhan, arsitektur YOLOv8n standar layak diimplementasikan untuk deteksi real-time pada aplikasi bank sampah berbasis mobile, dengan peluang peningkatan melalui perluasan variasi data pelatihan.

REFERENSI

- [1] J. Pendidikan Tambusai, E. Mahpudin, R. Lumban Batu, Z. Aulia Nurul Putri, P. Studi Akuntansi, and U. Singaperbangsa Karawang, "Pengelolaan Sampah Rumah Tangga di Kabupaten Karawang."
- [2] E. Nurcahyo and D. Ernawati, "PENGKATAN KESADARAN MASYARAKAT DALAM PENGELOLAAN SAMPAH RUMAH TANGGA DI DESA MABULUGO, KABUPATEN BUTON." [Online]. Available: <https://www.kajianpustaka.com/2017/03/pengertian-bentuk-dan-tahapan-kebijakan-publik.html>
- [3] Kepala Biro Hubungan Masyarakat KLHK Nunu Anugrah, "Oase Kabinet dan KLHK Ajak Masyarakat Kelola Sampah Organik Menjadi Kompos," Kementerian Lingkungan Hidup dan Kehutanan. Accessed: Oct. 14, 2024. [Online]. Available: <https://www.menlhk.go.id/news/klhk-ajak-masyarakat-kelola-sampah-organik-jadi-kompos/>
- [4] Bank Sampah Bersinar, "Bank Sampah Bersinar," <https://www.banksampahbersinar.com/>. Accessed: Oct. 14, 2024. [Online]. Available: <https://www.banksampahbersinar.com/>
- [5] K. O'Shea and R. Nash, "An Introduction to Convolutional Neural Networks," Nov. 2015, [Online]. Available: <http://arxiv.org/abs/1511.08458>
- [6] M. Hussain, "YOLOv1 to v8: Unveiling Each Variant-A Comprehensive Review of YOLO," *IEEE Access*, vol. 12, pp. 42816–42833, 2024, doi: 10.1109/ACCESS.2024.3378568.
- [7] K. V. Archana and G. Komarasamy, "A novel deep learning-based brain tumor detection using the Bagging ensemble with K-nearest neighbor," *J. Intell. Syst.*, vol. 32, no. 1, 2023, doi: 10.1515/jisys-2022-0206.
- [8] M. Sheykhou, M. Mahdianpari, H. Ghanbari, F. Mohammadmanesh, P. Ghamisi, and S. Homayouni, "Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 13, pp. 6308–6325, 2020, doi: 10.1109/JSTARS.2020.3026724.
- [9] S. Saidah, R. Purnamasari, A. N. Bainuri, and G. S. F. Wahid, "Analisis Perbandingan Metode LBP dan CLBP pada Sistem Pengenalan Individu Melalui Iris Mata," *J. Edukasi dan Penelit. Inform.*, vol. 6, no. 3, p. 285, 2020, doi: 10.26418/jp.v6i3.41521.
- [10] M. Safaldin, N. Zaghdene, and M. Mejdoub, "An Improved YOLOv8 to Detect Moving Objects," *IEEE Access*, vol. 12, pp. 59782–59806, 2024, doi: 10.1109/ACCESS.2024.3393835.