

Implementasi YOLOv5n untuk Deteksi Sampah Sungai Berbasis Computer Vision

Bagas Sulistyo ¹, Lela Nurpulaela ², Andrean Hosea Simanjuntak ³, Rifky Abilio Faizal ⁴, Henokh Markiano Louhanapessy ⁵

¹ Universitas Singaperbangsa Karawang; email : 2110631160037@student.unsika.ac.id

² Universitas Singaperbangsa Karawang; email : lela.nurpulaela@ft.unsika.ac.id

³ Universitas Singaperbangsa Karawang; email : 2110631160032@student.unsika.ac.id

⁴ Universitas Singaperbangsa Karawang; email : 2110631160021@student.unsika.ac.id

⁵ Universitas Singaperbangsa Karawang; email : 2110631160078@student.unsika.ac.id

Penulis : Bagas Sulistyo

Abstract: River pollution caused by waste has become a serious environmental issue in Indonesia. This study developed an automated waste detection system using the YOLOv5n model, which is lightweight and suitable for IoT-based devices. A total of 700 images were annotated into 17 waste categories using Roboflow and trained on Google Colab for 150 epochs. Model evaluation resulted in a mAP@0.5 of 0.417 and mAP@0.5:0.95 of 0.236. The model showed strong performance in classes with abundant data, such as plastic and tree branches, but performed poorly on minority classes like balls and sandals. Visualizations through confusion matrix and evaluation curves support these findings. Local testing using a river camera demonstrated reliable real-time detection capabilities. The results confirm that YOLOv5n is effective for high-efficiency waste detection and has strong potential for integration into automated river-cleaning boat systems. This finding provides a foundation for further development of AI-based systems for sustainable water waste management.

Keywords: Object detection; YOLOv5n; River waste; Computer vision; Roboflow; Deep learning;

Abstrak: Pencemaran sungai akibat sampah menjadi persoalan lingkungan yang serius di Indonesia. Penelitian ini mengembangkan sistem deteksi sampah otomatis menggunakan model *YOLOv5n*, yang ringan dan cocok untuk perangkat berbasis *Internet of Things*. Sebanyak 700 gambar dianotasi dalam 17 kelas menggunakan *Roboflow*, lalu dilatih di *Google Colab* selama 150 *epoch*. Evaluasi model menunjukkan mAP@0.5 sebesar 0.417 dan mAP@0.5:0.95 sebesar 0.236. Model memiliki performa tinggi pada kelas dengan data melimpah seperti plastik dan ranting kayu, namun lemah pada kelas minoritas seperti bola dan sandal. Visualisasi berupa *confusion matrix* dan kurva evaluasi mendukung temuan ini. Pengujian lokal menggunakan kamera sungai menunjukkan kemampuan deteksi real-time yang cukup akurat. Hasil penelitian membuktikan bahwa *YOLOv5n* efektif untuk mendeteksi sampah dengan efisiensi tinggi, dan berpotensi diterapkan pada sistem kapal pembersih otomatis. Temuan ini menjadi dasar pengembangan sistem berbasis *Artificial Intelligence* untuk pengelolaan sampah perairan secara berkelanjutan.

Kata kunci: Deteksi objek; *YOLOv5n*; Sampah sungai; *Computer vision*; *Roboflow*; *Deep learning*;

Diterima: Mei 17, 2025
Direvisi: Mei 27, 2025
Diterima: Juni 29, 2025
Diterbitkan: Juli 22, 2025
Versi sekarang: Juli 22, 2025



Hak cipta: © 2025 oleh penulis.
Diserahkan untuk kemungkinan
publikasi akses terbuka
berdasarkan syarat dan ketentuan
lisensi Creative Commons
Attribution (CC BY SA) (
<https://creativecommons.org/licenses/by-sa/4.0/>)

1. Pendahuluan

Lingkungan hidup merupakan anugerah yang menopang kelangsungan hidup manusia dan menjadi tempat berjalannya seluruh sistem kehidupan secara harmonis. Dalam konteks masyarakat Indonesia, lingkungan mencerminkan nilai-nilai kearifan lokal yang erat dengan keseimbangan ekosistem[1]. Namun, laju pertumbuhan penduduk yang tidak diimbangi dengan kesadaran lingkungan telah memicu berbagai persoalan ekologis, termasuk

meningkatnya pencemaran air[2]. Salah satu bentuk pencemaran yang kian mengkhawatirkan adalah penumpukan sampah di kawasan perairan seperti sungai, danau, dan saluran kota[3]. Sampah yang tidak tertangani dengan baik berpotensi menurunkan kualitas lingkungan, mengganggu kenyamanan hidup, serta menimbulkan risiko kesehatan masyarakat[4]. Sungai memiliki posisi strategis dalam mendukung aktivitas manusia. Selain sebagai sumber air bersih, sungai juga digunakan untuk keperluan domestik, irigasi, perikanan, hingga pembangkit energi dan transportasi. Fungsi sungai kerap terganggu akibat limbah rumah tangga dan industri yang dibuang sembarangan[5].

Di Indonesia, pengelolaan sampah masih belum optimal. Kurangnya edukasi dan kesadaran masyarakat mengakibatkan praktik pembuangan sampah ke sungai terus terjadi, sehingga memperparah degradasi kualitas air[6]. Kemajuan teknologi memberikan peluang untuk menjawab permasalahan ini melalui pendekatan berbasis *computer vision* dan kecerdasan buatan. Salah satunya adalah pemanfaatan sistem deteksi objek otomatis untuk mengidentifikasi sampah secara visual. Teknologi ini membuka peluang pengembangan sistem yang lebih efisien dan adaptif untuk mengidentifikasi sampah secara *real-time*. Penelitian ini mengusulkan penggunaan model *YOLOv5n*, varian ringan dari keluarga *YOLOv5*, untuk mendeteksi berbagai jenis sampah di perairan sungai. Model ini dipilih karena memiliki ukuran parameter yang kecil dan kecepatan inferensi tinggi, sehingga ideal untuk implementasi pada sistem tertanam berbasis *IoT*, seperti kapal pembersih sampah otomatis.

2. Tinjauan Literatur

2.1. Penelitian Terdahulu

Berbagai penelitian telah dilakukan untuk mengembangkan sistem deteksi sampah berbasis teknologi visi komputer. Pangaribuan dan Barri[7] mengembangkan sistem klasifikasi sampah menggunakan *SSD-MobileNet v2* dan menunjukkan efisiensi komputasi tinggi, namun akurasi menurun pada latar kompleks. Tantowi[8] memanfaatkan pengolahan citra klasik pada robot pengumpul sampah air, tetapi sistemnya sangat sensitif terhadap pencahayaan. Santoso dan Gamar[9] menggunakan *YOLOv4-Tiny* untuk deteksi botol plastik di sungai dan memperoleh hasil memadai dalam lingkungan dinamis, meskipun hanya terbatas pada satu kelas objek. Dari berbagai studi tersebut, terlihat bahwa sebagian besar penelitian masih terbatas pada jenis sampah tertentu, lingkungan terkontrol, atau belum mempertimbangkan kondisi riil sungai dengan variasi kelas sampah yang tinggi dan latar belakang kompleks. Selain itu, belum banyak penelitian yang mengevaluasi performa *YOLOv5n* sebagai model *lightweight* untuk deteksi multi-kelas sampah sungai menggunakan *dataset* lokal. Oleh karena itu, penelitian ini bertujuan mengisi celah tersebut dengan mengembangkan dan menguji sistem deteksi 17 kelas sampah secara *real-time* berbasis *YOLOv5n* yang dilatih menggunakan data sungai lokal dan diimplementasikan secara lokal menggunakan perangkat komputasi terbatas.

2.2. Sampah

Sampah merupakan hasil sisa dari aktivitas manusia yang tidak lagi memiliki nilai guna, tidak diinginkan, dan pada akhirnya dibuang ke lingkungan. Keberadaannya tidak terjadi secara alami, melainkan merupakan produk dari berbagai kegiatan domestik, komersial, maupun industri. Berdasarkan karakteristiknya, sampah dapat diklasifikasikan menjadi dua jenis utama, yaitu sampah organik yang mudah terurai seperti sisa makanan dan dedaunan, serta sampah anorganik yang sulit terurai, seperti plastik, logam, dan kaca[10].

2.3 Pencemaran Sungai

Sungai memiliki peran strategis dalam menunjang kehidupan masyarakat, tidak hanya sebagai sumber air bersih, tetapi juga sebagai jalur transportasi, irigasi, serta pendukung berbagai aktivitas ekonomi dan sosial. Namun, meningkatnya pembuangan sampah ke badan sungai berdampak pada menurunnya kualitas air, terganggunya aliran, dan rusaknya habitat akuatik[11]. Penyebab utama kondisi ini antara lain rendahnya kesadaran masyarakat terhadap pentingnya pengelolaan sampah yang baik, serta belum optimalnya sistem pengolahan limbah yang tersedia. Oleh karena itu, pendekatan teknologi berbasis otomatisasi menjadi krusial untuk mengurangi ketergantungan terhadap metode konvensional yang terbatas dalam cakupan dan efisiensinya.

2.4. Deteksi Objek

Deteksi objek merupakan salah satu teknik inti dalam bidang visi komputer yang berfungsi untuk mengenali dan menentukan posisi objek dalam suatu citra atau rekaman

video. Teknologi ini umumnya mengandalkan pendekatan *machine learning* dan *deep learning* guna memperoleh hasil yang akurat dan efisien. Sama halnya seperti cara kerja manusia dalam mengenali objek secara intuitif ketika melihat gambar, sistem deteksi objek dirancang untuk meniru kemampuan tersebut melalui proses komputasi[12]. Teknologi ini telah banyak digunakan dalam berbagai bidang, seperti sistem pengawasan, kendaraan tanpa pengemudi, serta analisis citra di bidang medis[13].

2.5 Algoritma YOLO (You Only Look Once)

YOLO merupakan salah satu pendekatan deteksi objek berbasis *Convolutional Neural Network (CNN)* yang banyak digunakan dalam pemrosesan citra digital. Ciri khas dari YOLO adalah kemampuannya dalam memproses seluruh gambar sekaligus baik saat pelatihan maupun pengujian sehingga memungkinkan model untuk mempertahankan konteks spasial yang penting untuk proses klasifikasi dan deteksi[14]. Mekanisme kerja YOLO dimulai dengan membagi gambar input menjadi sejumlah *grid*. Masing-masing *grid* bertugas memprediksi *bounding box* dan skor keyakinan (*confidence score*) terhadap kemungkinan keberadaan objek dalam wilayahnya. Setiap *bounding box* yang dihasilkan oleh sel *grid* menyertakan lima parameter utama: koordinat pusat (x, y), dimensi (w, h), dan skor kepercayaan. Parameter (x, y) menunjukkan letak pusat kotak relatif terhadap *grid*, sementara (w, h) menggambarkan ukuran kotak relatif terhadap dimensi citra asli. *Confidence score* digunakan untuk menunjukkan tingkat keyakinan model terhadap keberadaan objek, sekaligus mengukur tingkat kesesuaian antara prediksi dan *ground truth* melalui nilai *Intersection over Union (IoU)*[15]. YOLOv5, versi yang dikembangkan oleh Ultralytics, menghadirkan berbagai pilihan ukuran model, termasuk YOLOv5n (*nano*) yang dirancang untuk kebutuhan komputasi rendah pada perangkat *embedded*. Keunggulan utama algoritma YOLO terletak pada efisiensi waktu inferensi dan kemampuannya mendeteksi banyak objek secara simultan dalam satu proses analisis.

2.6. Roboflow

Roboflow adalah platform berbasis cloud yang dirancang untuk menyederhanakan proses pengembangan sistem visi komputer, mulai dari tahap penyusunan dataset hingga pelatihan dan penyebaran model. Sejak dirilis pada awal tahun 2020, Roboflow telah digunakan oleh ratusan ribu pengembang untuk mengelola proyek deteksi objek dengan lebih efisien[16]. Selain menyediakan antarmuka anotasi yang intuitif, Roboflow juga dilengkapi dengan teknologi AutoML (*Automated Machine Learning*), yang secara otomatis mengonfigurasi parameter pelatihan sehingga pengguna tidak perlu mengatur hiperparameter secara manual. Fitur ini memungkinkan pelatihan model yang optimal dengan sedikit intervensi teknis. Platform ini dikembangkan oleh Deci AI, perusahaan yang berfokus pada optimasi performa model AI. Roboflow juga menyediakan infrastruktur pelatihan berbasis cloud dengan akses GPU yang kuat, memungkinkan pengguna untuk menjalankan pelatihan model melalui *endpoint API* yang telah dihosting secara online[17]. Hal ini menjadikan Roboflow sebagai solusi lengkap untuk siklus pengembangan model deteksi objek, terutama dalam proyek yang melibatkan data visual dalam jumlah besar.

2.7 Google Colab

Google Colaboratory, atau lebih dikenal sebagai Google Colab, merupakan lingkungan pengembangan Python berbasis cloud yang disediakan secara gratis oleh Google. Platform ini memungkinkan pengguna untuk menulis, mengedit, dan mengeksekusi kode Python langsung dari browser tanpa perlu konfigurasi lokal[18]. Google Colab sangat populer dalam pengembangan aplikasi berbasis pembelajaran mesin, karena menyediakan akses ke sumber daya komputasi tinggi seperti GPU dan TPU (*Tensor Processing Unit*) yang dapat digunakan untuk pelatihan model skala besar[19]. Selain kemudahan akses, Colab juga mendukung kolaborasi secara real-time antar pengguna, sehingga sangat mendukung kerja tim dalam proyek pengembangan perangkat lunak atau penelitian akademik. Setiap sesi kerja di Colab didukung oleh mesin virtual (VM) yang telah dilengkapi dengan pustaka-pustaka populer untuk data science, sehingga mempercepat proses eksperimen dan eksplorasi data[20].

3. Metode

Penelitian ini bertujuan mengembangkan dan menguji model deteksi sampah berbasis YOLOv5n melalui tahapan sistematis mulai dari pengumpulan data, pelabelan, pelatihan model, evaluasi, hingga pengujian lokal. Seluruh proses dilakukan menggunakan Roboflow, Google Colab, dan Visual Studio Code di laptop lokal.

3.1. Pengumpulan dan Labeling Dataset

Tahap awal dalam penelitian ini adalah pengumpulan dataset berupa gambar sampah di lingkungan sungai, kanal, atau permukaan air lainnya. Sebanyak 700 gambar diperoleh melalui pengambilan langsung maupun sumber daring. Gambar-gambar tersebut kemudian diberi anotasi (*label*) menggunakan *platform Roboflow*, yaitu dengan menandai *bounding box* dan memberikan label kategori pada objek sampah yang ditemukan. Sebanyak 17 kelas objek sampah digunakan, antara lain: plastik, botol plastik, ranting kayu, sterofoam, masker, botol kaleng, sepatu, sendal, dan lainnya. Setelah proses *labeling*, dataset diekspor dalam format YOLO dan dibagi menjadi data pelatihan (80%), validasi (10%), dan uji (10%).

3.2. Arsitektur Model YOLOv5n

Model yang digunakan adalah YOLOv5n, varian ringan dari keluarga YOLOv5 yang dikembangkan oleh Ultralytics. Model ini memiliki sekitar 2,5 juta parameter, sehingga cocok untuk pengujian di perangkat dengan daya komputasi rendah. Arsitektur YOLOv5n terdiri dari tiga bagian utama, yaitu :

- *Backbone (CSPDarknet)*: mengekstraksi fitur dari citra masukan;
- *Neck (PANet)*: menggabungkan fitur dari berbagai skala;
- *Head*: menghasilkan bounding box dan klasifikasi objek.

YOLOv5n dipilih karena ukurannya yang kecil dan kecepatan inferensinya yang tinggi, membuatnya ideal untuk pengujian di perangkat lokal dan sistem tertanam ke depannya.

3.3. Pelatihan Model di Google Colab

Pelatihan model dilakukan di *Google Colaboratory* dengan bantuan GPU NVIDIA Tesla T4. Proyek YOLOv5 dari Ultralytics di-clone langsung dari repositori resmi *GitHub*. Dataset dari *Roboflow* diimpor ke *Colab* menggunakan *API*, kemudian dimasukkan ke dalam *pipeline* pelatihan YOLOv5. Konfigurasi pelatihan sebagai berikut:

- *Epoch*: 150 *Batch*
- *size*: 16
- *Image size*: 640×640 piksel
- *Optimizer*: default (SGD)
- *Model*: YOLOv5n

Proses pelatihan menghasilkan model deteksi (*best.pt*) yang kemudian disimpan untuk tahap pengujian.

3.4. Evaluasi Kinerja Model

Model dievaluasi berdasarkan empat metrik utama:

- *Precision*: ketepatan model dalam mendeteksi objek yang benar.
- *Recall*: kemampuan model dalam menemukan semua objek yang relevan.
- *mAP@0.5*: rata-rata presisi pada ambang batas *Intersection over Union (IoU)* sebesar 0.5.
- *mAP@0.5:0.95*: rata-rata mAP pada berbagai tingkat ambang *IoU*.

Hasil evaluasi menunjukkan nilai *mAP@0.5* sebesar 0.417 dan *mAP@0.5:0.95* sebesar 0.236. Beberapa kelas seperti ranting kayu dan plastik memiliki skor deteksi tinggi, sementara kelas dengan jumlah data sedikit, seperti bola dan sendal, menunjukkan akurasi rendah.

3.5. Implementasi Lokal di Laptop

Model terbaik dari pelatihan (*best.pt*) diimplementasikan secara lokal menggunakan laptop berbasis *Visual Studio Code (VSC)*. Lingkungan uji mencakup:


- *Python 3.11*
- *PyTorch*
- *OpenCV*
- *Library YOLOv5* dari *Ultralytics*

Hasilnya, model mampu mendeteksi objek sampah seperti plastik, botol, dan ranting kayu dengan akurasi cukup baik. Tahapan ini menjadi validasi awal sebelum sistem diintegrasikan ke perangkat.

4. Hasil dan Pembahasan

4.1 . Pengumpulan *Dataset*


Dataset terdiri dari 700 gambar yang mencerminkan kondisi nyata sungai dan kanal, diperoleh dari pengambilan langsung serta sumber *daring*. Gambar tersebut dianotasi secara manual di *Roboflow* dan diklasifikasikan ke dalam 17 kelas seperti plastik, botol plastik, botol kaleng, eceng gondok, ranting kayu, dan lainnya. Gambar kemudian dibagi menjadi 80% data pelatihan, 10% validasi, dan 10% pengujian.



Gambar 1. *Datasheet* pada *Roboflow*


4.2 . Hasil Pelatihan Model

Model dilatih selama 150 *epoch* menggunakan *YOLOv5n* dengan konfigurasi *image size* 640×640 dan *batch size* 16. Model menunjukkan hasil akhir berupa nilai $mAP@0.5$ sebesar 0.417 dan $mAP@0.5:0.95$ sebesar 0.236.



Gambar 2. *Recall* dan *Precision Curve*

Hasil pelatihan model *YOLOv5n* menunjukkan performa yang beragam untuk setiap kelas sampah. Gambar *Recall-Confidence Curve* dan *Precision-Confidence Curve* pada Gbr. 2 memberikan gambaran kemampuan model dalam mendeteksi objek pada berbagai tingkat kepercayaan (*confidence*). Sementara itu, *F1-Confidence Curve* pada Gbr. 3 menunjukkan *trade-off* antara *precision* dan *recall* untuk setiap kelas.




Gambar 3. *F1-Confidence Curve*

Recall-Confidence Curve memperlihatkan bahwa beberapa kelas seperti ranting kayu, plastik, dan batu memiliki tingkat *recall* yang tinggi pada hampir seluruh rentang *confidence*, menunjukkan bahwa model cenderung mampu mendeteksi objek-objek ini secara konsisten. Namun, kelas seperti bola dan sandal memiliki *recall* mendekati nol, yang mengindikasikan bahwa model gagal mengenali objek tersebut secara efektif. Hal ini bisa disebabkan oleh jumlah data yang sangat sedikit untuk kelas-kelas tersebut dalam *dataset*. *Precision-Confidence Curve* menunjukkan bahwa kelas seperti ranting kayu dan plastik tidak hanya sering terdeteksi tetapi juga cukup akurat, terlihat dari *precision* tinggi di *confidence* menengah hingga tinggi. Sebaliknya, kelas seperti botol dan bungkus rokok memiliki *precision* yang fluktuatif, menandakan ketidakstabilan prediksi pada kelas dengan sampel sedikit. *F1-Confidence Curve* yang menggabungkan kedua metrik sebelumnya menunjukkan bahwa performa optimal model secara keseluruhan terjadi pada *confidence* sekitar 0.35, dengan nilai *F1* sebesar 0.186. Nilai ini merupakan hasil kompromi terbaik antara *precision* dan *recall* pada seluruh kelas.

Kelas dengan *F1* tertinggi adalah ranting kayu dan plastik, yang menunjukkan keseimbangan deteksi yang baik. Sebaliknya, kelas seperti sandal dan bola memiliki *F1 score* mendekati nol, kembali mengindikasikan rendahnya kinerja model pada kelas minoritas. Secara umum, hasil pelatihan menunjukkan bahwa performa model sangat dipengaruhi oleh distribusi jumlah data pada masing-masing kelas. Kelas dengan jumlah data lebih banyak cenderung memiliki performa yang lebih stabil dan akurat, mendukung pentingnya data yang seimbang untuk pembelajaran mendalam.


4.3 . Visualisasi *Confusion Matrix*

Confusion matrix merupakan alat evaluasi yang menggambarkan performa klasifikasi model terhadap kelas-kelas objek. Gbr. 4 menunjukkan *confusion matrix* dalam bentuk absolut (jumlah prediksi), sedangkan Gbr. 5 menyajikannya dalam bentuk normalisasi (persentase keberhasilan relatif terhadap jumlah data per kelas).



Gambar 4. Confusion matrix

Gbr. 4 menunjukkan bahwa kelas plastik dan ranting kayu memiliki prediksi yang sangat tinggi dengan nilai diagonal masing-masing sebesar 76 dan 79, mengindikasikan bahwa model dapat mengenali objek-objek tersebut dengan akurasi tinggi. Hal ini sejalan dengan jumlah instance yang cukup banyak pada kedua kelas tersebut di dalam *dataset*. Sebaliknya, terdapat beberapa kelas dengan performa klasifikasi rendah, seperti botol dan sendal, yang sama sekali tidak dikenali dengan benar (nilai diagonal 0). Kesalahan klasifikasi juga cukup sering terjadi pada kelas botol plastik dan eceng gondok, yang terkadang diprediksi sebagai *background* atau kelas lainnya. Hal ini bisa disebabkan oleh kemiripan visual atau keterbatasan jumlah data pelatihan untuk kelas tersebut.



Gambar 5. Confusion Matrix Normalized

Gbr. 5 memberikan representasi *confusion matrix* dalam format yang telah dinormalisasi, memperlihatkan persentase akurasi relatif per kelas. Nilai prediksi benar tertinggi ditunjukkan oleh warna biru tua, misalnya pada kelas ranting kayu (0.95) dan plastik (0.68). Di sisi lain, kelas seperti bungkus rokok dan botol kaleng menunjukkan nilai prediksi benar yang rendah, mengindikasikan bahwa model masih kesulitan membedakan objek-objek tersebut. Secara umum, *confusion matrix* ini membantu mengidentifikasi kelas-kelas yang membutuhkan peningkatan kualitas dataset maupun teknik augmentasi. Visualisasi ini juga memperkuat

temuan dari kurva evaluasi sebelumnya, seperti *F1* dan *Precision-Recall Curve*, yang menunjukkan bahwa performa model sangat tergantung pada distribusi dan representasi data dari masing-masing kelas.

4.4 . Implementasi Sistem

Setelah proses pelatihan selesai, model didesain untuk diimplementasikan secara langsung menggunakan laptop melalui *Visual Studio Code*. Implementasi ini dilakukan dengan menggunakan kamera untuk menangkap video dari aliran sungai secara *real-time*. Model deteksi sampah kemudian mengidentifikasi objek-objek di dalam aliran air, termasuk botol plastik, gelas plastik, dan batu, sebagaimana ditampilkan pada Gbr. 6 dan Gbr. 7.



Gambar 6. Deteksi botol dan gelas plastik di sungai.

Gbr. 6 menunjukkan keberhasilan model dalam mendeteksi dua jenis sampah, yaitu botol plastik dan gelas plastik, lengkap dengan estimasi jarak terhadap kamera dan posisi objek dalam *frame*. Keberhasilan deteksi tersebut ditandai dengan skor *confidence* masing-masing sebesar 0.32 dan 0.50, yang mengindikasikan bahwa model memiliki keyakinan moderat hingga tinggi terhadap prediksi objek.



Gambar 7. Deteksi batu di sungai

Sementara itu, Gbr. 7 memperlihatkan deteksi terhadap objek non-sampah, yaitu batu, dengan *confidence* sebesar 0.27. Hal ini menunjukkan bahwa model tidak hanya mendeteksi sampah, tetapi juga mampu membedakan jenis objek lain yang mungkin mengganggu proses identifikasi sampah di sungai. Penerapan model ini memperlihatkan bahwa sistem deteksi dapat berfungsi secara responsif di lingkungan sungai yang sesungguhnya. Deteksi dilakukan secara *real-time*, memberikan informasi jenis sampah, jarak dari kamera, serta posisi arah objek (kanan, tengah, kiri), yang dapat berguna untuk sistem pengambilan keputusan navigasi pada kapal pengumpul sampah di masa depan.

4.5 . Pembahasan

Hasil evaluasi menunjukkan bahwa *YOLOv5n*, sebagai varian *lightweight* dari keluarga *YOLO*, mampu memberikan performa deteksi yang kompetitif dalam konteks sistem berbasis *IoT*. Dengan nilai $mAP@0.5$ sebesar 0.417 dan $mAP@0.5:0.95$ sebesar 0.236, model menunjukkan kemampuan deteksi yang memadai pada beberapa kelas utama seperti plastik, ranting kayu, dan eceng gondok. Hal ini mengindikasikan bahwa model cukup mampu mengenali objek dengan fitur visual yang konsisten dan distribusi data yang seimbang. Namun, kinerja model menurun drastis pada kelas dengan jumlah data sangat rendah seperti bola, sandal, dan sepatu, yang tercermin dari nilai *recall* dan *mAP* yang mendekati nol. Hal ini menguatkan temuan dalam penelitian terdahulu bahwa *YOLO* sangat sensitif terhadap ketimpangan distribusi kelas, dan performa dapat ditingkatkan melalui strategi augmentasi data atau penyeimbangan jumlah sampel per kelas. Meskipun begitu, keunggulan *YOLOv5n* terletak pada efisiensi komputasinya. Dengan hanya 2,5 juta parameter, model dapat dijalankan secara lokal tanpa *GPU*, menjadikannya ideal untuk sistem tertanam seperti kapal pembersih sampah berbasis *IoT*. Kecepatan inferensi dan ukuran model yang kecil memungkinkan integrasi langsung ke sistem *real-time* tanpa mengorbankan akurasi secara signifikan.

Secara keseluruhan, hasil ini mendukung hipotesis bahwa *YOLOv5n* merupakan pilihan yang tepat untuk sistem deteksi sampah di lingkungan sungai, di mana keterbatasan daya komputasi dan kebutuhan akan respons waktu nyata menjadi tantangan utama. Penelitian ini juga membuka peluang untuk eksplorasi lanjutan dengan memperluas jumlah data, mengadopsi teknik *transfer learning*, serta mengintegrasikan model dengan sistem navigasi otomatis pada kapal pembersih sampah.

5. Kesimpulan

Penelitian ini menunjukkan bahwa model *YOLOv5n* dapat digunakan secara efektif untuk mendeteksi berbagai jenis sampah di sungai dengan akurasi yang cukup baik, meskipun model ini termasuk dalam kategori *lightweight*. Nilai $mAP@0.5$ sebesar 0.417 dan $mAP@0.5:0.95$ sebesar 0.236 menandakan bahwa model mampu memberikan hasil deteksi yang andal pada beberapa kelas utama seperti plastik dan ranting kayu. Hal ini menunjukkan bahwa model mampu beroperasi secara *real-time* dalam sistem berbasis *IoT* dengan keterbatasan daya komputasi. Temuan ini mendukung hipotesis bahwa *YOLOv5n* cocok diterapkan pada kapal pengumpul sampah otomatis berbasis visi komputer. Performanya cenderung baik pada kelas dengan jumlah data besar dan ciri visual kuat, namun menurun signifikan pada kelas minor yang datanya minim. Oleh karena itu, keberimbangan dataset merupakan faktor penting dalam pengembangan sistem ini. Visualisasi berupa *confusion matrix*, kurva evaluasi, dan pengujian langsung menunjukkan konsistensi model dalam mengidentifikasi objek dalam kondisi lingkungan sebenarnya. Kontribusi utama dari penelitian ini adalah pengembangan *pipeline* deteksi sampah yang efisien dan dapat diterapkan secara lokal tanpa perangkat keras khusus. Penelitian ini juga menjadi pijakan awal menuju integrasi sistem deteksi dengan sistem navigasi otomatis kapal. Untuk pengembangan selanjutnya, disarankan melakukan ekspansi *dataset*, penerapan augmentasi data, dan eksplorasi model lain seperti *YOLOv8n* atau *transfer learning* untuk meningkatkan kinerja pada kelas minoritas.

Kontribusi Penulis: Konseptualisasi: Bagas Sulisty; Metodologi, Perangkat Lunak, Analisis, Investigasi, Visualisasi: Bagas Sulisty; Validasi: Bagas Sulisty, Andrean Hosea, Rifky Abilio, Henokh Markiano; Kurasi Data, Penulisan Awal, Administrasi: Bagas Sulisty; Peninjauan & Penyuntingan: Bagas Sulisty, Lela Nurpulaela; Supervisi: Lela Nurpulaela;

Pendanaan: Penelitian ini tidak menerima pendanaan eksternal.

Pernyataan Ketersediaan Data: *Dataset* dan model pelatihan yang digunakan dalam penelitian ini tersedia dalam platform *Roboflow* dan dapat dibagikan atas permintaan kepada penulis korespondensi.

Ucapan Terima Kasih: Penulis mengucapkan terima kasih kepada pihak-pihak yang telah memberikan dukungan moral dan teknis dalam proses pelaksanaan penelitian ini.

Konflik Kepentingan: Penulis menyatakan tidak ada konflik kepentingan.

Referensi

- [1] B. Ismaya, I. Bakti, dan S. Suparni, "Penerapan Bank Sampah Sebagai Solusi Mengatasi Ekosentris Lingkungan di Bantaran Sungai Citarum," *J. Pengabd. Kpd. Masy.*, vol. 1, no. 6, 2023.
- [2] N. C. Elvania, "Upaya Pengendalian Pencemaran Air Sungai Kalitidu Di Desa Jelu, Kecamatan Kalitidu, Kabupaten Bojonegoro," *Media Ilm. Tek. Lingkung.*, vol. 7, no. 1, hlm. 17–23, Apr 2022, doi: 10.33084/mitl.v7i1.3351.
- [3] M. Mauliadi, M. Basyir, dan A. Finawan, "Rancang Bangun Robot Boat Pemungut Sampah Di Perairan Waduk Lhokseumawe Berbasis Mikrokontroler".
- [4] A. Rahayu, "Upaya Pengendalian Pencemaran Sungai yang Diakibatkan Sampah di Desa Muka Paya, Kecamatan Hinai, Sumatera Utara".
- [5] N. Novianti, B. Zaman, dan A. Sarminingsih, "Kajian Status Mutu Air dan Identifikasi Sumber Pencemaran Sungai Cidurian Segmen Hilir Menggunakan Metode Indeks Pencemaran (IP)," *J. Ilmu Lingkung.*, vol. 20, no. 1, hlm. 22–29, Jan 2022, doi: 10.14710/jil.20.1.22-29.
- [6] R. Alfandi, D. Erwanto, dan D. E. Yuliana, "Rancang Bangun Robot Kapal Pembersih Sampah Tenaga Surya Menggunakan Modul ESP32-CAM Dengan Kontrol Melalui Smartphone".
- [7] P. W. Muhammad Valdi, P. Pangaribuan, dan M. H. Barri, "Sistem Pemilah Sampah Berbasis Deep Learning dengan Algoritma SSD-MobileNet v2," no. Vol. 11 No. 1 (2024): Februari 2024, Feb 2024.
- [8] R. Tantowi, "Kendali Conveyor Pada Robot Pengumpul Sampah Di Permukaan Air Bebas Image Processing," Politeknik Negeri Sriwijaya, Palembang, 2022.
- [9] U. R. Nur Santoso dan F. Gamar, "Deteksi Sampah Botol Plastik di Perairan Menggunakan YOLO v4-Tiny," *J. Teknol. Dan Sist. Inf. Bisnis*, vol. 7, no. 1, hlm. 91–98, Jan 2025, doi: 10.47233/jteksis.v7i1.1744.
- [10] Z. Zuraidah, L. N. Rosyidah, dan R. F. Zulf, "Edukasi Pengelolaan Dan Pemanfaatan Sampah Anorganik Di Mi Al Munir Desa Gadungan Kecamatan Puncu Kabupaten Kediri," *BUDIMAS J. Pengabd. Masy.*, vol. 4, no. 2, Okt 2022, doi: 10.29040/budimas.v4i2.6547.
- [11] A. P. Utami, N. N. A. Pane, dan A. Hasibuan, "Analisis Dampak Limbah/Sampah Rumah Tangga Terhadap Pencemaran Lingkungan Hidup".
- [12] J. Pardede dan H. Hardiansah, "Deteksi Objek Kereta Api menggunakan Metode Faster R-CNN dengan Arsitektur VGG 16," *MIND J.*, vol. 7, no. 1, hlm. 21–36, Jun 2022, doi: 10.26760/mindjournal.v7i1.21-36.
- [13] L. Palupi, E. Ihsanto, dan F. Nugroho, "Analisis Validasi dan Evaluasi Model Deteksi Objek Varian Jahe Menggunakan Algoritma YOLOv5," *J. Inf. Syst. Res. JOSH*, vol. 5, no. 1, hlm. 234–241, Okt 2023, doi: 10.47065/josh.v5i1.4380.
- [14] K. Khairunnas, E. M. Yuniarno, dan A. Zaini, "Pembuatan Modul Deteksi Objek Manusia Menggunakan Metode YOLO untuk Mobile Robot," *J. Tek. ITS*, vol. 10, no. 1, Agu 2021, doi: 10.12962/j23373539.v10i1.61622.
- [15] A. N. Sugandi dan B. Hartono, "Implementasi Pengolahan Citra pada Quadcopter untuk Deteksi Manusia Menggunakan Algoritma YOLO," 2022.
- [16] R. T. Hutabarat dan R. Kurniawan, "Deteksi Sampah di Permukaan Sungai menggunakan Convolutional Neural Network dengan Algoritma YOLOv8," *Semin. Nas. Off. Stat.*, vol. 2024, no. 1, hlm. 537–548, Nov 2024, doi: 10.34123/semnasoffstat.v2024i1.2099.
- [17] N. Khairunissa dan R. Suwandi, "Sistem Pendeteksi Ketersediaan Tempat Duduk Pada Perpustakaan Berbasis Computer Vision. Studi Kasus : Perpustakaan Unand Ruangn The Gade Creative Lounge," vol. 06, no. 01, 2025.
- [18] R. Gelar Guntara, "Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7," *J. Teknol. Dan Sist. Inf. Bisnis*, vol. 5, no. 1, hlm. 55–60, Feb 2023, doi: 10.47233/jteksis.v5i1.750.
- [19] Febby Wilyani, Qonaah Nuryan Arif, dan Fitri Aslimar, "Pengenalan Dasar Pemrograman Python Dengan Google Colaboratory," *J. Pelayanan Dan Pengabd. Masy. Indones.*, vol. 3, no. 1, hlm. 08–14, Mar 2024, doi: 10.55606/jppmi.v3i1.1087.
- [20] T. R. Abdillah, "Analisis Komparasi Cycles X Render Dan Cycles Render Menggunakan Google Colab," *J. TIK4*, vol. 8, no. 1, hlm. 90–94, Apr 2023, doi: 10.51179/tika.v8i1.1937.