

PENERAPAN OBJECT DETECTION MENGGUNAKAN DEEP LEARNING YOLOV8 UNTUK MENGIDENTIFIKASI SAMPAH ANORGANIK (MAKSIMAL SEPULUH OBJEK) DALAM SATU CITRA

Visen^{*1}, Novrido Charibaldi²

^{1,2}Universitas Pembangunan Nasional (UPN) Veteran Yogyakarta
Email: ¹viseenn@gmail.com, ²novrido@upnyk.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 15 Mei 2024, diterima untuk diterbitkan: 11 Februari 2025)

Abstrak

Masalah sampah di Indonesia masih menjadi momok yang belum teratasi, terutama karena tingginya pertumbuhan penduduk. Sampah anorganik menjadi perhatian utama karena sulit terurai dan mencemari lingkungan untuk waktu yang lama. Oleh karena itu, diperlukan sistem pendeteksi otomatis berbagai jenis sampah anorganik dalam berbagai kondisi, guna mengurangi dampak pencemaran dan memfasilitasi proses daur ulang yang lebih efisien. Penelitian ini menggunakan kecerdasan buatan (*deep learning*) dengan model YOLOv8 nano untuk mengenali beberapa jenis sampah anorganik. Data yang dipakai berasal dari kamera gawai dan gabungan *dataset* Kaggle, totalnya ada 2459 data untuk lima jenis sampah. Pembagian datanya 1967 untuk pelatihan, 246 untuk validasi, dan 246 untuk pengujian. Pengujian dilakukan pada gambar yang berisi 1 hingga 12 objek sampah dalam kondisi yang berbeda-beda. Hasilnya menunjukkan akurasi model yang tinggi, dengan nilai mAP50 mencapai 87.1% dan mAP50-95 sebesar 72.1%. Nilai presisi mencapai 86.2% dan *recall* mencapai 79.1% pada iterasi ke-50, menunjukkan kinerja model yang baik. Model ini juga handal dalam mendeteksi hingga sepuluh objek sampah dalam satu gambar. Namun, kemampuan deteksi menurun ketika objek sampah melebihi sepuluh. Artinya, model masih bisa mengenali objek meski jumlahnya banyak, tetapi akurasi klasifikasinya menurun.

Kata kunci: Sampah Anorganik, Deep Learning, Deteksi Sampah, Deteksi Multi-Objek, YOLOv8

IMPLEMENTATION OF OBJECT DETECTION USING DEEP LEARNING YOLOV8 TO IDENTIFY FIVE TYPES OF INORGANIC WASTE (MAXIMUM TEN OBJECTS) IN A SINGLE IMAGE

Abstract

The waste problem in Indonesia remains a persistent issue, especially due to the high population growth. Inorganic waste is a major concern because it is difficult to decompose and contaminates the environment for a long time. Therefore, an automatic detection system for various types of inorganic waste in different conditions is needed to reduce the impact of pollution and facilitate more efficient recycling processes. This study uses artificial intelligence (*deep learning*) with the YOLOv8 nano model to recognize several types of inorganic waste. The data used comes from mobile phone cameras and a combination of Kaggle datasets, totaling 2,459 data points for five types of waste. The data is divided into 1,967 for training, 246 for validation, and 246 for testing. The testing was conducted on images containing 1 to 12 waste objects in various conditions. The results show a high model accuracy, with an mAP50 value of 87.1% and mAP50-95 of 72.1%. The precision value reaches 86.2%, and the recall reaches 79.1% at the 50th iteration, indicating good model performance. This model is also reliable in detecting up to ten waste objects in a single image. However, the detection ability decreases when the number of waste objects exceeds ten. This means that the model can still recognize objects even when there are many, but its classification accuracy decreases.

Keywords: Inorganic Waste, Deep Learning, Waste Detection, Multi-Object Detection, YOLOv8

1. PENDAHULUAN

Pengelolaan sampah di Indonesia menjadi salah satu tantangan utama yang dihadapi, dengan laporan dari Kementerian Lingkungan Hidup dan Kehutanan

menunjukkan bahwa sekitar 5.948.380 ton sampah masih belum dikelola (Kementerian Lingkungan Hidup dan Kehutanan, 2024). Penanganan sampah masih belum optimal, terutama karena jumlah dan

ragam sampah terus bertambah seiring dengan pertumbuhan penduduk Indonesia (Ibnul Rasidi et al., 2022; Faizal, Yuyun and Hazriani, 2023). Sampah organik dapat terurai secara alami, sedangkan sampah anorganik sulit atau bahkan tidak bisa terurai, berdampak negatif pada lingkungan (Suraya et al., n.d.).

Saat ini, pemilahan sampah dapat dilakukan secara manual atau menggunakan teknologi. Pemilahan manual melibatkan pekerja yang memisahkan sampah berdasarkan jenisnya secara langsung, tetapi metode ini membutuhkan banyak tenaga dan waktu, terutama bergantung pada jumlah sampah yang harus dipilah (Sandi et al., 2022). Penggunaan teknologi dalam pemilahan sampah menjadi solusi yang efisien dan berkelanjutan (Sandi et al., 2022; Tri Juniati et al., 2023). Teknologi memungkinkan identifikasi, pemisahan, dan pengelompokan sampah berdasarkan jenisnya tanpa perlu campur tangan manusia secara langsung. Teknologi seperti *deep learning*, pemrosesan citra, dan robotika dapat dimanfaatkan untuk pemilahan sampah secara otomatis dan akurat.

Dalam bidang *deep learning*, terdapat beberapa metode yang digunakan untuk deteksi dan klasifikasi objek, seperti *Convolutional Neural Network* (CNN), *Faster R-CNN*, *Support Vector Machine* (SVM), dan *You Only Look Once* (YOLO). Penelitian sebelumnya telah menjelajahi berbagai pendekatan tersebut. Misalnya, (Fadhilur Rahman, 2020) menggunakan metode *Faster R-CNN* untuk deteksi sampah pada video *real-time*, mencapai akurasi sebesar 74%, namun dengan kebutuhan sumber daya komputasi yang besar.

Penelitian yang dilakukan oleh (Ibnul Rasidi et al., 2022) berhasil mencapai tingkat akurasi sebesar 96% untuk sampah anorganik dan 62% untuk sampah organik. Hasil penelitian ini menunjukkan bahwa meskipun CNN memiliki performa tinggi, tetapi masih mengalami keterbatasan dalam mendeteksi objek yang memiliki kemiripan baik dari segi bentuk maupun warna.

Studi yang dilakukan oleh (Wibisono, 2023) berhasil mencapai tingkat nilai akurasi 93,72%, dengan nilai *loss* sebesar 0,2283, dan waktu pelatihan selama 20,97 menit. Namun, penelitian ini mengalami kekurangan dalam mendeteksi beberapa objek dalam satu citra.

Penelitian yang dilakukan oleh (Leonardo, Yohannes and Hartati, 2020) menguji performa data dalam beberapa *fold* dengan menggunakan beberapa kernel SVM, termasuk kernel linear, *polynomial*, dan gaussian. Hasilnya menunjukkan bahwa kernel linear mencapai tingkat akurasi yang lebih tinggi daripada kernel *polynomial* dan gaussian, dengan rata-rata nilai akurasi berkisar antara 84% hingga 93%. Meskipun akurasi cukup tinggi, terdapat beberapa kelemahan dalam performa SVM yang sangat bergantung pada fitur yang diekstraksi. Selain itu, SVM masih memiliki keterbatasan dalam mendeteksi beberapa

jenis sampah dalam satu citra, serta dalam menangani situasi ketika terdapat beberapa kelas sampah dalam satu gambar.

Namun, penelitian sebelumnya masih belum sepenuhnya berhasil menyelesaikan tantangan dalam mendeteksi beberapa jenis sampah dalam satu citra dengan tingkat akurasi yang tinggi. *You Only Look Once* (YOLO) merupakan salah satu model *deep learning* yang bertujuan untuk mengenali objek-objek (Karlina and Indarti, 2019). Dalam penelitian ini, akan menggunakan algoritma YOLOv8 dengan tujuan untuk mengevaluasi kinerja model dalam mendeteksi dan mengklasifikasikan beberapa jenis sampah anorganik dalam satu citra. Pemilahan YOLOv8 dilakukan karena kemampuannya untuk memberikan tingkat akurasi yang tinggi, meminimalkan kebutuhan komputasi, serta memiliki kemampuan untuk mendeteksi beberapa objek dalam satu citra (Yanto, Aziz and Irmawati, 2023). Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam meningkatkan akurasi dan keandalan deteksi sampah anorganik di Indonesia, terutama dalam menghadapi tantangan deteksi sampah yang beragam jenis dan jumlahnya dalam satu gambar.

2. METODE/PERANCANGAN

Penelitian ini dilakukan secara sistematis dengan tujuan membangun sistem deteksi lima jenis sampah anorganik dengan menggunakan model YOLOv8n untuk mengidentifikasi objek-objek dalam satu citra.

2.1 Pengumpulan Data

Data yang akan digunakan terdiri dari data primer dan data sekunder. Data primer diperoleh melalui pengambilan gambar menggunakan perangkat gawai, sementara data sekunder diperoleh dari gabungan beberapa dataset yang tersedia di situs Kaggle. Dataset sampah anorganik terdiri dari lima kelas, yaitu *cardboard* dengan 395 citra, *glass* dengan 491 citra, *metal* dengan 579 citra, *paper* dengan 562 citra, dan *plastic* dengan 577 citra. Dari jumlah tersebut, sebanyak 50 citra dari masing-masing kelas berasal dari data primer.

2.2 Preprocessing Data

Preprocessing data adalah langkah awal yang diperlukan untuk menyiapkan data sebelum digunakan dalam proses pelatihan dengan model YOLOv8n (Nugraha Kasmara et al., 2024). Dalam penelitian ini, terdapat lima tahapan yang dilakukan, yaitu anotasi, *splitting*, *resize*, augmentasi, dan duplikasi. Untuk melaksanakan tahapan tersebut, digunakan website <https://universe.roboflow.com>. Anotasi dilakukan dengan menandai objek pada citra menggunakan kotak pembatas dan nama *label* (Maulidiansyah and Yaqin, 2023; Yanto, Aziz and Irmawati, 2023). Setelah anotasi selesai, data dibagi menjadi tiga bagian, yaitu *training*, *validasi*, dan


pengujian, dengan perbandingan 80%, 10%, dan 10%. Seluruh data yang telah dibagi kemudian diubah ukurannya menjadi 640x640 piksel. Augmentasi dilakukan untuk mencegah *underfitting*, sehingga menciptakan variasi citra yang lebih beragam. Hal ini diharapkan model dapat mengenali objek dalam berbagai kondisi dan meningkatkan akurasi prediksi. Terdapat 14 kombinasi variasi augmentasi, seperti *flip*, rotasi, kecerahan, *noise*, dan *shear*. Hasil dari augmentasi kemudian diduplikasi secara manual untuk membantu model dalam mengenali objek dengan lebih baik. Berikut adalah hasil akhir pembagian untuk masing-masing jenis dataset setelah *preprocessing* data.

Tabel 1. Pembagian Data

Jenis data	Jumlah data	Rasio
Training	11802	80%
Validasi	246	10%
Pengujian	246	10%
Total	12294	100%

2.3 Implementasi Model YOLOv8n

Penerapan model YOLOv8 dilakukan menggunakan lingkungan pengembangan Google Colab IDE. Saat ingin menerapkan model YOLOv8, diperlukan untuk mengunduh pustaka *ultralytics* dan *roboflow*.



Gambar 1. Alur Implementasi

Dataset yang telah disiapkan akan diimpor untuk dilatih menggunakan model YOLOv8n. *Dataset* yang diimpor sudah mencakup label dan *file* konfigurasi, seperti *data.yaml*, yang akan digunakan dalam proses pelatihan. *File* konfigurasi tersebut mencakup informasi tentang kelas, jumlah kelas, konfigurasi *roboflow*, dan *path* untuk data pelatihan, validasi, dan pengujian. Model YOLOv8n memiliki 3011823 parameter dan terdiri dari 225 lapisan, termasuk berbagai jenis lapisan seperti lapisan konvolusi, lapisan blok, dan lapisan deteksi.

2.4 Evaluasi Model

Model yang telah dibuat akan dievaluasi dengan menggunakan *confusion matrix* dan mAP (*Mean*

Average Precision). Untuk mendapatkan nilai mAP, harus memperhitungkan nilai AP yang diperoleh dari perhitungan presisi dan *recall*.

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AveragePrecision_k \quad (1)$$

Confusion matrix digunakan untuk mengevaluasi kinerja model dalam mengklasifikasikan citra (Bagas Prakosa and Radius Tanone, 2023).

3. HASIL DAN PEMBAHASAN

Di bagian hasil, akan diuraikan temuan dari penelitian yang telah dilakukan dalam beberapa subbagian sebagai berikut.

3.1. Pengumpulan Data dan *Preprocessing* Data

Data yang telah terkumpul telah disortir secara manual untuk memastikan kualitasnya. Setelah penyortiran, dilanjutkan dengan langkah *preprocessing* data. Proses ini mencakup anotasi, *splitting*, augmentasi, dan *resize* menggunakan *platform* *roboflow*. Hasil anotasi disimpan dalam file berekstensi *.txt* yang mencatat kelas, koordinat titik x dan y objek, panjang, dan lebar dari *bounding box* (Sani and Rahmadinni, 2022). Pengkodean kelas dilakukan dengan aturan bahwa angka 0 mengindikasikan kelas *cardboard*, angka 1 untuk kelas *glass*, angka 2 untuk kelas *metal*, angka 3 untuk kelas *paper*, dan angka 4 untuk kelas *plastic*. Total data yang terhimpun mencapai 2459 citra, yang melibatkan lima kelas sampah anorganik. Semua data telah dianotasi, menghasilkan total 3516 anotasi, dengan rata-rata 1,4 anotasi per citra. Berikut adalah gambaran representatif dari anotasi untuk masing-masing kelas.

Tabel 2. Representasi Anotasi

Kelas	Data training	Data validation	Data testing
<i>cardboard</i>	376	46	51
<i>metal</i>	644	59	94
<i>glass</i>	589	56	87
<i>paper</i>	539	55	68
<i>plastic</i>	691	86	75

3.2 Implementasi Model YOLO

Langkah pertama dalam menerapkan model YOLO adalah mengimpor *library*. *Ultralytics* digunakan untuk deteksi objek berbasis *deep learning*. Modul *ultralytics* memiliki kelas YOLO yang dapat digunakan dalam mendeteksi objek, menganalisis, dan memproses hasil deteksi. *Dataset* diakses melalui Google Drive yang terhubung dengan Google Colab. Model YOLO diinisialisasi sebelum dilatih dengan *data training*. *File* konfigurasi disiapkan sebelum melatih model dengan mengatur *hyperparameter*, seperti jumlah *epoch*. Berikut merupakan beberapa *hyperparameter* yang digunakan dalam pelatihan model.

Tabel 3. *Hyperparameter*


<i>Hyperparameter</i>	Nilai
Optimizer	AdamW
Learning rate	0,001111
Momentum	0,9
Epoch	50

Proses pelatihan menghasilkan nilai *box_loss*, *cls_loss*, *mAP50*, dan *mAP50-95* seperti pada Tabel 3. *Box loss* akan menggambarkan seberapa baik model dapat menentukan pusat objek dan seberapa baik *bounding box* yang diprediksi mencakup objek tersebut. *Classification loss* memberikan Gambaran seberapa baik model dapat memprediksi kelas yang tepat dari suatu objek yang diprediksi (Kasper-Eulaers et al., 2021). *mAP50* menunjukkan sejauh mana model mampu mendeteksi objek dengan tingkat akurasi minimal 50%. Sementara itu, *mAP50-95* menggambarkan kemampuan model dalam mendeteksi objek di berbagai kondisi yang berbeda.


Tabel 4. Hasil Pelatihan Model

Epoch	<i>Box_loss</i>	<i>Cls_loss</i>	<i>mAP50</i>	<i>mAP50-95</i>
1	1.3639	2.4476	0.47535	0.3115
2	1.3894	1.9188	0.57726	0.36569
3	1.3936	1.807	0.61937	0.40239
...	...	...	...	...
48	0.7458	0.4131	0.84708	0.6931
49	0.7384	0.4075	0.84466	0.69301
50	0.7313	0.4008	0.84105	0.6904

Hasil pelatihan model dapat dilihat dalam bentuk grafik yang menampilkan *box loss* dan *classification loss* untuk data pelatihan dan validasi. Berikut adalah visualisasi grafiknya.

Gambar 2. Grafik *Box Loss*

Grafik tersebut menampilkan performa model dalam mempelajari data dan menggeneralisasi data yang belum pernah dilihat sebelumnya. Menurunnya nilai *loss training* dan *loss validation* menandakan model berhasil mempelajari dan menggeneralisasi data.

Gambar 3. Grafik *Classification Loss*

Grafik *classification loss* digunakan untuk mengetahui kinerja model dalam mengklasifikasikan objek. Semakin rendah *classification loss*, semakin baik dalam mengklasifikasikan objek.

Setelah dilakukan implementasi model dilanjutkan dengan pengujian terhadap data validasi. Pengujian menggunakan data validasi dilakukan untuk mengevaluasi kemampuan model serta mengukur seberapa besar kemungkinan *overfitting* pada data. Proses pengujian model menggunakan data validasi menghasilkan empat nilai, yaitu nilai presisi, *recall*, *mAP50*, dan *mAP50-95*.


Tabel 5. Hasil Pengujian dengan Data Validasi

Kelas	P	R	<i>mAP50</i>	<i>mAP50-95</i>
<i>all</i>	0.861	0.791	0.871	0.721
<i>cardboard</i>	0.891	0.892	0.917	0.749
<i>glass</i>	0.967	0.786	0.888	0.772
<i>metal</i>	0.838	0.881	0.922	0.81
<i>paper</i>	0.86	0.668	0.84	0.657
<i>plastic</i>	0.749	0.727	0.789	0.617

Berdasarkan grafik, dapat dilihat bahwa hasil terbaik dengan *hyperparameter* yang dipilih tercapai sebelum *epoch* ke-46. Setelah itu, *loss validasi* mulai meningkat, yang menunjukkan potensi *overfitting* pada model. Kelas “all” dalam tabel mengacu pada keseluruhan kelas sampah anorganik (*cardboard*, *glass*, *metal*, *paper*, dan *plastic*) yang diuji dalam model. Hasil yang ditampilkan pada kelas “all” adalah rata-rata dari metrik-metrik untuk seluruh kelas tersebut.


3.3 Evaluasi Model Klasifikasi

Pada tahap evaluasi ini, model terbaik yang dilatih akan dievaluasi. Evaluasi akan melibatkan penggunaan *confusion matrix*, nilai presisi, *recall*, dan *mAP*. *Confusion matrix* untuk model akan ditampilkan dalam Gambar 4.




Gambar 4. Confusion Matrix

Kelas *background* merujuk pada bagian gambar yang tidak termasuk dalam kategori objek. Kelas *background* memberikan informasi tentang seberapa baik model dapat membedakan antara objek yang relevan dan tidak relevan (*background*). Visualisasi dari nilai presisi, *recall*, mAP50, dan mAP50-95 akan ditampilkan dalam bentuk grafik sebagai berikut.




Gambar 5. Precision

Grafik menggambarkan peningkatan nilai presisi secara bertahap seiring dengan penambahan *epoch*. Dari grafik tersebut, terlihat bahwa kinerja model semakin baik seiring berjalannya waktu.




Gambar 6. Recall

Garis pada grafik tersebut menunjukkan arah yang menaik, yang berarti *recall* meningkat seiring dengan waktu. *Recall* yang tinggi menandakan bahwa model mampu dengan tepat mengenali Sebagian besar data positif. mAP50 menunjukkan akurasi deteksi objek setidaknya 50%, sedangkan mAP50-95 menunjukkan kemampuan deteksi objek dalam berbagai kondisi.



Gambar 7. mAP50



Gambar 8. mAP50-95

4. HASIL PENGUJIAN CITRA

Pengujian citra dilakukan untuk menilai kinerja model dalam mengidentifikasi berbagai jenis sampah anorganik yang terdapat dalam satu gambar. Citra sampah anorganik yang digunakan untuk pengujian mencakup berbagai objek, mulai dari satu hingga sepuluh objek. Citra yang digunakan dalam pengujian berbeda dari citra yang ada dalam *dataset*. Citra diambil dari internet secara acak agar mengetahui kinerja model atau hasil prediksi terhadap citra yang tidak pernah dilihat.

Tabel 6. Hasil Pengujian Citra				
No	Citra Sampah Anorganik	Jumlah Prediksi & Hasil	Aktual	Kesimpulan
1.		1 objek Benar	1 objek	Berhasil karena dapat mendeteksi 1 objek <i>cardboard</i>
2.		2 objek Benar	2 objek	Berhasil karena dapat mendeteksi 2 objek <i>paper</i>
3.		3 objek Benar	3 objek	Berhasil karena dapat mendeteksi 3 objek <i>metal</i>

Tabel 7. Hasil Pengujian Citra (Lanjutan)

No	Citra Sampah Anorganik	Jumlah Prediksi & Hasil	Aktual	Kesimpulan
4.		4 objek Benar	4 objek	Berhasil karena dapat mendeteksi 2 objek <i>plastic</i> dan 2 objek <i>paper</i>
5.		5 objek Benar	5 objek	Berhasil karena dapat mendeteksi 2 objek <i>cardboard</i> , 2 objek <i>glass</i> , dan 1 objek <i>plastic</i>
6.		6 objek Benar	6 objek	Berhasil karena dapat mendeteksi 2 objek <i>plastic</i> dan 4 objek <i>paper</i>
7.		7 objek Benar	7 objek	Berhasil karena dapat mendeteksi 7 objek <i>paper</i>
8.		8 objek Benar	8 objek	Berhasil karena dapat mendeteksi 8 objek <i>plastic</i>
9.		9 objek Benar	9 objek	Berhasil karena dapat mendeteksi 9 objek <i>cardboard</i>
10.		10 objek Benar	10 objek	Berhasil karena dapat mendeteksi 10 objek <i>plastic</i>
11.		11 objek Salah	11 objek	Gagal karena salah mendeteksi seharusnya 11 objek <i>plastic</i> , tetapi terdeteksi 14 objek <i>plastic</i> Gagal karena salah mendeteksi seharusnya 12 objek <i>glass</i> , tetapi terdeteksi 11 objek <i>glass</i> dan 1 objek <i>metal</i>
12.		12 objek Salah	12 objek	

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa sistem berhasil mendeteksi beberapa jenis sampah anorganik dalam satu citra dengan baik dan menghasilkan nilai evaluasi yang baik. Model dilatih dengan 50 *epoch*, menghasilkan mAP50 sebesar 87.1 % dan mAP50-95 sebesar 72.1%. Tingkat *precision*

mencapai 86.2%, sementara *recall* sebesar 79.1%. Selama pelatihan, tercatat *box loss* sebesar 0.7313 dan *classification loss* sebesar 0.4008.

Model mampu mengidentifikasi objek dalam jumlah satu hingga sepuluh dengan baik dan akurat dalam satu citra. Namun, kinerjanya menurun ketika menghadapi citra dengan lebih dari sepuluh objek, disebabkan oleh kompleksitas tambahan dari citra tersebut. Kompleksitas citra mengacu pada jumlah objek dalam citra dan kondisi objek dalam citra seperti tumpang tindih. Meskipun model dapat melakukan deteksi atau lokalisasi pada citra yang memiliki lebih dari sepuluh objek, namun tidak mampu mengklasifikasikan jenis sampah anorganik dengan benar.

Dalam rangka meningkatkan kualitas model dalam mendeteksi sampah anorganik, dianjurkan untuk menambah jumlah data *training* dengan objek yang lebih banyak dalam satu citra serta variasi kondisi objek yang tumpang tindih. Selain itu, *dataset* perlu diperluas dengan menambahkan jenis sampah anorganik lainnya. Dengan demikian, model dapat diperkuat dengan data yang lebih representatif dan variasi yang lebih luas, sehingga meningkatkan kemampuannya dalam mengenali dan mengklasifikasikan sampah anorganik dengan lebih baik.

DAFTAR PUSTAKA

- BAGAS PRAKOSA, A. AND RADIUS TANONE, 2023. Implementasi Model Deep Learning Convolutional Neural Network (CNN) Pada Citra Penyakit Daun Jagung Untuk Klasifikasi Penyakit Tanaman. Jurnal Pendidikan Teknologi Informasi (JUKANTI), 6(1), hlm.107-112.
- FADHILUR RAHMAN, M., 2020. Deteksi Sampah pada Real-time Video Menggunakan Metode Faster R-CNN. Applied Technology and Computing Science Journal, hlm.117-125.
- FAIZAL, L., YUYUN, Y. AND HAZRIANI, H., 2023. Identifikasi Sampah Plastik Menggunakan Algoritma Deep Learning. Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI), 6(2), hlm.162-171. <https://doi.org/10.57093/jisti.v6i2.176>.
- IBNUL RASIDI, A., PASARIBU, Y.A.H., ZIQRI, A. AND ADHINATA, F.D., 2022. Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network. Jurnal Teknik Informatika dan Sistem Informasi (JuTISI), 8(1), hlm.142-149. <https://doi.org/10.28932/jutisi.v8i1.4314>.
- KARLINA, O.E. AND INDARTI, D., 2019. Pengenalan Objek Makanan Cepat Saji Pada Video Dan Real Time Webcam Menggunakan Metode You Look Only Once (YOLO). Jurnal Ilmiah Informatika

- Komputer, 24(3), hlm.199–208.
<https://doi.org/10.35760/ik.2019.v24i3.2362>.
- KEMENTERIAN LINGKUNGAN HIDUP DAN KEHUTANAN, 2024. Sistem Informasi Pengelolaan Sampah Nasional. [online] Tersedia di: <https://sipsn.menlhk.go.id/sipsn/> [Diakses 11 April 2024].
- KASPER-EULAERS, M., HAHN, N., BERGER, S., SEBULONSEN, T., MYRLAND, Ø., & KUMMERVOLD, P. E. 2021. Short communication: Detecting heavy goods vehicles in rest areas in winter conditions using YOLOv5. *Algorithms*, 14(4), hlm.114.
<https://doi.org/10.3390/a14040114>
- LEONARDO, YOHANNES AND HARTATI, E., 2020. Klasifikasi Sampah Daur Ulang Menggunakan Support Vector Machine Dengan Fitur Local Binary Pattern. *Jurnal Ilmiah Mahasiswa Informatika (ALGORITME)*, 1(1), hlm.78-89.
- MAULIDIANSYAH AND YAQIN, A., 2023. Deteksi Tumpukan Sampah dengan Metode You Only Look Once (YOLO). *Jurnal Ilmu Teknologi, Kesehatan, dan Humaniora (TRILOGI)*, 4(2), hlm.76-79.
<https://doi.org/10.33650/trilogi.v4i2.6185>
- NUGRAHA KASMARA, B., TRI ESTI HANDAYANI, E., DIAN NATHASIA, N. AND NASIONAL, U., 2024. Perbandingan Kinerja Algoritma K-Nearest Neighbors (K-NN) Dan Decision Tree Dalam Deteksi Paket Malis Pada Jaringan. *Satuan Tulisan Riset dan Inovasi Teknologi (STRING)*, 8(3), hlm.320-329.
- SANDI, K.M., PRIMA YUDHA, A., DIMAS ARYANTO, N. AND FARABI, M.A., 2022. Klasifikasi sampah menggunakan Convolutional Neural Network. *Indonesian Journal of Data and Science (IJODAS)*, 3(2), hlm.72–81.
- SANI, A. AND RAHMADINNI, S., 2022. Deteksi Gestur Tangan Berbasis Pengolahan Citra. *Jurnal Rekayasa Elektrika*, 18(2).
<https://doi.org/10.17529/jre.v18i2.25147>.
- SURAYA, F., SAFITRI, E.A., MAULANA, W.R., PRATAMA, F.A. AND NAFISAH, D., n.d. Revitalisasi TPS 3R melalui Penyuluhan Pengelolaan Sampah dan Pelatihan Pembuatan Kompos dari Sampah Organik. *Jurnal Puruhita*, 3(1), hlm.22-30.
- TRI JUNIATI, A., NINGTYAS, A., PUTRI, F.K., REFLY, M. AND HIKNATULLAH, DAN M., 2023. Sistem Pengelolaan Sampah yang Efisien dan ramah lingkungan. *Seminar Rekayasa Teknologi (SEMRESTEK)*, hlm.348-357.
- WIBISONO, R.K., 2023. Skripsi-Full-Rafi-Khairuna-Wibisono. Universitas Pembangunan Nasional Veteran Yogyakarta.
- YANTO, AZIZ, F. AND IRMAWATI, 2023. YOLO-V8 Peningkatan Algoritma Untuk Deteksi Pemakaian Masker Wajah. *Jurnal Mahasiswa Teknik Informatika (JATI)*, 7(3), hlm.1437-1444.

Halaman ini sengaja dikosongkan