

OPTIMASI MODEL KLASIFIKASI CITRA SAMPAH DAUR ULANG DENGAN ALGORITMA YOLO11

Anggita Aprilla^[1]; Willy Prihartono^[2]; Cep Lukman Rohmat^[3]

Program Studi Teknik Informatika^{[1][2]}, Program Studi Rekayasa Perangkat Lunak^[3]
Sekolah Tinggi Manajemen Informatika dan Komputer IKMI Cirebon^{[1][2][3]}
anggiaaprilla99@gmail.com

INFO ARTIKEL	INTISARI
Diajukan : 25 November 2024	<i>Masalah pengelolaan limbah, terutama sampah anorganik seperti plastik, kaca, kardus, dan logam, menjadi tantangan signifikan dalam mewujudkan keberlanjutan lingkungan. Penelitian ini bertujuan meningkatkan akurasi klasifikasi sampah daur ulang berbasis citra dengan memanfaatkan algoritma YOLO11 yang telah dioptimalkan. Dataset penelitian terdiri dari 400 gambar sampah yang dikumpulkan melalui observasi lapangan, menggunakan latar belakang putih untuk mempertegas kontras objek. Proses penelitian mencakup tahap preprocessing data (meliputi resizing dan pembagian data), pelatihan model dengan rasio data 80:20, serta evaluasi kinerja menggunakan metrik akurasi, precision, recall, dan F1-score. Model dilatih selama lima epoch menggunakan bobot awal pada algoritma YOLO11. Hasil penelitian menunjukkan model mampu mencapai akurasi keseluruhan sebesar 98,7%, dengan precision 98,8%, recall 98,7%, dan F1-score 98,7%. Pengujian pada data eksternal juga membuktikan kemampuan model dalam menggeneralisasi, meskipun terdapat beberapa kendala pada pencahayaan dan sudut pandang tertentu. Temuan ini menggarisbawahi potensi besar algoritma YOLO11 untuk mendukung otomatisasi pengelolaan sampah daur ulang, seperti dalam pemisahan material di fasilitas daur ulang atau aplikasi berbasis edukasi mobile. Untuk pengembangan lebih lanjut, disarankan memperluas variasi dataset dan mengeksplorasi algoritma lain guna mendukung pengelolaan sampah yang lebih optimal dan berkelanjutan.</i>
Diterima : 01 Desember 2024	
Diterbitkan: 19 Desember 2024	
Kata Kunci : klasifikasi, sampah daur ulang, pengolahan citra, deep learning, algoritma yolo	

I. PENDAHULUAN

Jumlah sampah anorganik di seluruh dunia telah meningkat sebagai akibat dari peningkatan konsumsi plastik, kertas, kaca, dan logam. Situasi ini membutuhkan manajemen limbah yang lebih efisien, terutama untuk mendukung program daur ulang. Algoritma YOLO (*You Only Look Once*) adalah salah satu contoh teknologi berbasis kecerdasan buatan (AI) yang dapat mendeteksi berbagai jenis objek dalam berbagai lingkungan (Budiyanta, Mulyadi, dan Tanudjaja 2021). Namun, masalah akurasi dalam berbagai lingkungan menunjukkan bahwa model saat ini harus diperbarui. Tujuan penelitian ini adalah untuk menggunakan algoritma YOLO11 yang telah dioptimalkan untuk meningkatkan efisiensi dan akurasi klasifikasi sampah daur ulang sesuai dengan upaya keberlanjutan lingkungan (Aprilino dan Al Amin 2022).

Salah satu masalah utama di banyak negara, termasuk Indonesia, adalah sampah anorganik yang tidak terkelola dengan baik. Volume sampah yang meningkat, terutama plastik dan logam, mengganggu ekosistem di darat dan laut (Hasibuan

2023). Pemilahan sampah secara manual membutuhkan banyak waktu dan tenaga, sehingga penerapan teknologi AI dapat menjadi alternatif yang lebih efisien. Meskipun algoritma YOLO terkenal dengan kecepatan dan tingkat akurasinya, penerapannya dalam klasifikasi sampah masih menghadapi tantangan, terutama pada kondisi lingkungan seperti pencahayaan yang kurang memadai dan latar belakang yang rumit (Liunanda, Rostianingsih, dan Purbowo 2020). Oleh karena itu, penelitian ini berfokus pada pengembangan model yang lebih canggih untuk mendeteksi sampah dalam berbagai kondisi.

Studi literatur menunjukkan bahwa model seperti YOLO belum banyak digunakan dalam daur ulang, meskipun mereka memiliki potensi besar. Dengan menggunakan YOLOv3 untuk klasifikasi gambar makanan, penelitian lain menunjukkan kecepatan deteksi yang sangat tinggi dan akurasi hingga 96% (Rahma et al. 2021). Selain itu, penelitian tentang pemanfaatan ulang kertas di Indonesia menunjukkan bahwa volume sampah dapat berkurang hingga 10,2% per tahun melalui daur ulang (A. Z. Saputra dan Fauzi 2022). Dalam

konteks aplikasi UI/UX, pendekatan berbasis *design thinking* juga telah berhasil meningkatkan efektivitas aplikasi pengolahan limbah (Ardiansyah dan Rosyani 2023). Hal ini menunjukkan perlunya model yang lebih spesifik dan adaptif untuk digunakan dalam klasifikasi sampah daur ulang berbasis gambar.

Pendekatan berbasis pengolahan citra dengan algoritma YOLO11 dipilih karena kemampuannya dalam mendeteksi objek dengan cepat dan akurat. *Dataset* yang digunakan mencakup gambar sampah seperti plastik, kardus, logam, dan kaca yang diambil menggunakan kamera. Teknik *supervised learning* akan digunakan untuk melatih model YOLO11 agar mampu mengenali berbagai jenis sampah dengan lebih baik. Metode ini juga telah diterapkan dalam klasifikasi jenis kendaraan dengan hasil yang menjanjikan (Iskandar Mulyana dan Rofik 2022). Hasil klasifikasi akan dianalisis berdasarkan akurasi dan kecepatan proses untuk memastikan efektivitas model yang dikembangkan (Aprilino dan Al Amin 2022; Nafis Alfarizi et al. 2023).

Penelitian ini bertujuan meningkatkan akurasi klasifikasi sampah daur ulang berbasis citra menggunakan algoritma YOLO11 yang dioptimalkan. Dengan menerapkan teknologi pengenalan objek, penelitian ini diharapkan mendukung keberlanjutan lingkungan melalui pengelolaan sampah yang lebih efisien. Hasilnya dapat dimanfaatkan oleh pengelola sampah atau instansi terkait untuk meningkatkan program daur ulang. Selain itu, implementasi teknologi berbasis AI juga berpotensi membantu edukasi masyarakat tentang pentingnya pemilahan sampah sejak dini, seperti yang diterapkan dalam pengembangan gim edukasi berbasis Android untuk daur ulang (Wahyudinata dan Dirgantara 2020).

Dengan menggunakan teknologi kecerdasan buatan, penelitian ini diharapkan dapat memberikan kontribusi signifikan untuk pengelolaan sampah yang lebih baik. Pengelola sampah dan lembaga terkait dapat menggunakan sistem klasifikasi berbasis YOLO11 untuk meningkatkan program daur ulang (Liunanda, Rostianingsih, dan Purbowo 2020). Selain itu, penggunaan teknologi ini dapat membantu program lingkungan yang sedang berkembang dan meningkatkan kesadaran masyarakat akan pentingnya pemilahan sampah sejak dini (Hasibuan 2023). Pendekatan ini juga sejalan dengan penelitian sebelumnya yang menunjukkan bahwa algoritma klasifikasi berbasis citra, seperti *Support Vector Machine* (SVM), dapat memberikan hasil yang akurat dengan pemilihan fitur yang tepat, seperti *Local Binary Pattern* (Leonardo, Yohannes, dan Hartati 2020).

II. BAHAN DAN METODE

Metode penelitian yang digunakan adalah menggunakan metode kuantitatif. Metode kuantitatif adalah upaya menguji hipotesis dan menemukan pola atau hubungan antara variabel. Algoritma YOLO11 digunakan untuk mengolah data dalam penelitian yang berjudul Peningkatan Model Klasifikasi Sampah Daur Ulang Berbasis Citra. Fungsi algoritma ini adalah menemukan dan mengklasifikasikan objek dalam gambar dengan sangat cepat dan tepat berdasarkan dataset yang dikumpulkan dari observasi lapangan. Tahapan penelitian dapat dilihat pada gambar 1.

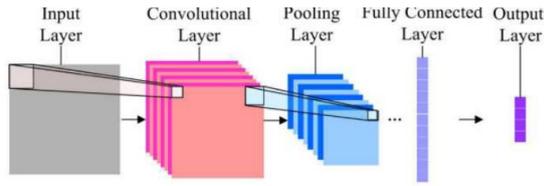


Gambar 1. Tahapan Penelitian

Data primer yang digunakan dalam penelitian ini berasal dari observasi lapangan yang dilakukan oleh Bank Sampah Dewi Sri, mitra Dinas Lingkungan Hidup Kabupaten Cirebon. Dengan menggunakan kamera aplikasi WhatsApp di Infinix Note 10 Pro, data dikumpulkan melalui dokumentasi sampah.

Setiap jenis sampah difoto dari berbagai sudut dan pencahayaan untuk memastikan variasi data, menggunakan latar belakang putih agar objek lebih kontras dan mempermudah proses segmentasi. Meskipun kamera WhatsApp tidak memiliki resolusi tinggi, ia tetap mengambil gambar berkualitas tinggi yang cukup untuk melatih model. Metode ini memungkinkan model YOLO11 untuk melakukan klasifikasi sampah dengan lebih akurat karena membantu mengidentifikasi fitur visual seperti bentuk dan lainnya.

Metode yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* (CNN). CNN adalah evolusi dari *Multilayer Perceptron* (MLP), yang dirancang untuk mengolah data dua dimensi (Sandi et al. 2022). Algoritma *deep learning*, yang menggunakan gambar sebagai *input*, membantu CNN mengidentifikasi objek dengan mengolahnya (Bahagia dan Akbar 2024). Gambar 2 (Alwanda, Ramadhan, dan Alamsyah 2020) menunjukkan langkah yang harus dilakukan untuk melakukan studi dengan metode ini: *Convolution*, *Pooling*, *Flattening*, *Full Connection*.



Gambar 2. Metode Convolutional Neural Network (CNN)

Proses *convolution layer* adalah mengeluarkan fitur dari gambar input. Operasi konvolusi melibatkan pemindahan filter ke seluruh gambar untuk menghasilkan peta fitur. Untuk meningkatkan efisiensi operasi CNN, lapisan *pooling* digunakan secara berurutan (Sandi et al. 2022). Setelah *pooling*, proses *flattening* digunakan untuk mengubah peta fitur menjadi vektor satu dimensi (R. A. Saputra, Putra, dan Asyrofi 2023). Lapisan *fully connected* digunakan untuk mengubah dimensi data sehingga dapat diklasifikasikan secara linear. Melalui penggunaan perkalian matriks yang diikuti oleh penambahan bias, proses ini tidak menggunakan operasi konvolusi (Alwanda, Ramadhan, dan Alamsyah 2020).

III. HASIL DAN PEMBAHASAN

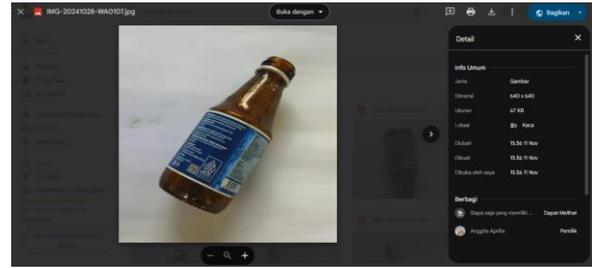
1. Data

Penelitian ini menggunakan data gambar JPG dari gambar sampah daur ulang untuk mengklasifikasikan jenis sampah berdasarkan materialnya. Sebanyak 400 gambar dari *dataset* dibagi ke dalam empat kategori utama: plastik, kaca, kardus, dan logam.

Data dikumpulkan secara langsung dari bank sampah Dewi Sri, yang merupakan mitra dari Dinas Lingkungan Hidup Kabupaten Cirebon dan bersifat eksklusif untuk keperluan penelitian ini saja, sehingga tidak akan dipublikasikan atau disebarluaskan ke pihak lain. Data dikumpulkan menggunakan kamera aplikasi WhatsApp di *smartphone* Infinix Note 10 Pro. *Dataset* kemudian diproses melalui tahap *labeling*, di mana setiap *dataset* dikelompokkan ke dalam folder menurut jenis sampahnya. Plastik, kaca, kardus, dan logam adalah nama folder yang digunakan untuk mengidentifikasi gambar yang ada di dalamnya.

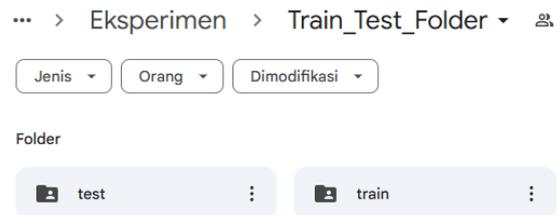
2. Preprocessing

Resizing adalah proses pertama dalam *preprocessing*, yang bertujuan untuk menyamakan ukuran seluruh gambar dalam *dataset* menjadi 640 x 640 piksel. Ukuran ini dipilih untuk memastikan bahwa setiap gambar memiliki resolusi yang sama dan sesuai dengan *input* standar model YOLO11, sehingga model dapat menganalisis setiap gambar tanpa melakukan penyesuaian ulang, yang mempercepat proses pelatihan.



Gambar 3. Hasil Resizing Data

Tahapan berikutnya adalah membagi *dataset* yang telah dilakukan *resizing* sebelumnya. Dalam proses ini, *dataset* gambar sampah dibagi menjadi dua bagian menggunakan modul *python_splitter*: data *train* (80 persen) dan data *test* (20 persen). Proses ini berhasil mengotomatiskan pembagian data dan membagi gambar ke dalam *folder Train* untuk data latihan dan *Test* untuk data uji. Dengan pembagian ini, diharapkan model YOLO11 dapat mengenali pola dalam gambar sampah dengan menggunakan data latihan dan diuji menggunakan data uji untuk mengevaluasi kemampuan generalisasinya terhadap gambar yang belum pernah dilihat sebelumnya.



Gambar 4. Folder Hasil Split Data

3. Training Model

Selanjutnya, model dilatih menggunakan data latih yang disimpan dalam *folder Train_Test_Folder*. Proses pelatihan dijalankan selama lima *epoch*, dengan setiap *epoch* adalah satu putaran pelatihan model pada seluruh data latih. Model akan mempelajari pola visual dalam data sampah (plastik, kaca, kardus, dan logam) selama pelatihan dan mengubah bobotnya untuk mengklasifikasikan jenis sampah dengan lebih baik.

```

m0s 755k/755k [00:00:00, 17.0MB/s]
 1/5  0  1/25  10  224: 100%  20/20 [00:40:00.00, 2.81s/1i]
      classes  top1_acc  top5_acc: 100%  3/3 [00:00:00.00, 2.89s/1i]
      all  0.712  1

Epoch  2/5  GPU_mem  0.760G  Instances  10  Size  224: 100%  20/20 [00:38:00.00, 1.94s/1i]
      classes  top1_acc  top5_acc: 100%  3/3 [00:07:00.00, 2.35s/1i]
      all  0.875  1

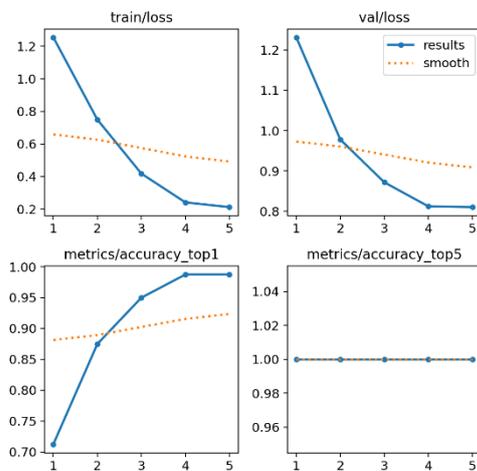
Epoch  4/5  GPU_mem  0.848G  Instances  10  Size  224: 100%  20/20 [00:38:00.00, 1.92s/1i]
      classes  top1_acc  top5_acc: 100%  3/3 [00:05:00.00, 2.21s/1i]
      all  0.95  1

Epoch  5/5  GPU_mem  0.812G  Instances  10  Size  224: 100%  20/20 [00:37:00.00, 1.88s/1i]
      classes  top1_acc  top5_acc: 100%  3/3 [00:05:00.00, 2.30s/1i]
      all  0.988  1
    
```

Gambar 5. Hasil Training Model

Hasil pelatihan menunjukkan bahwa model berhasil mencapai akurasi sebesar 98% pada data yang

dilatih setelah lima *epoch*. Hasil ini menunjukkan kemampuan model untuk mempelajari pola dengan baik. Selain itu, penurunan kehilangan pelatihan yang konsisten di setiap titik waktu menunjukkan bahwa proses pelatihan berjalan lancar tanpa adanya indikasi *overfitting*. Jika dibandingkan dengan hasil penelitian (Iskandar Mulyana dan Rofik 2022) yang menggunakan metode YOLOv5, yang mampu mengenali objek secara konsisten dengan tingkat akurasi 90%, menunjukkan bahwa model yang digunakan dalam penelitian ini memiliki tingkat akurasi yang lebih tinggi dan performa yang lebih baik dalam mengenali pola pada data latih.



Gambar 6. Visualisasi Hasil Training Model

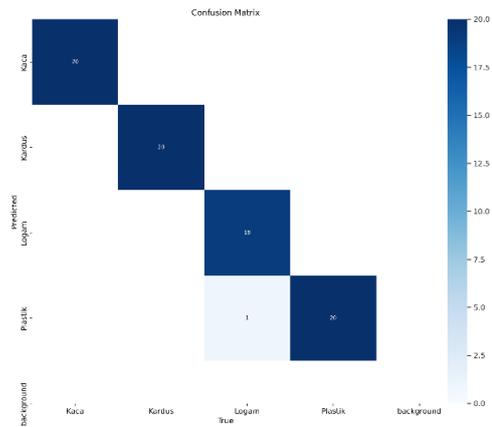
Gambar 6 merupakan visualisasi hasil training yang dapat dijelaskan sebagai berikut:

- Grafik *train/loss* (kiri atas) dan *val/loss* (kanan atas) menunjukkan penurunan yang konsisten seiring bertambahnya jumlah *epoch*. Hal ini menunjukkan bahwa model telah belajar dengan baik dari data pelatihan dan validasi.
- Penurunan *loss* yang tajam pada *epoch* awal menunjukkan bahwa model beradaptasi dengan cepat terhadap pola data, dan penurunan yang mendatar pada periode berikutnya menunjukkan proses konvergensi.
- Grafik *metrics/accuracy_top1* (kiri bawah) menunjukkan peningkatan akurasi yang konsisten hingga 0,95 (95%) pada periode terakhir. Ini menunjukkan bahwa model dapat mengklasifikasikan sampah dengan benar pada pilihan pertama.
- Grafik *metrics/accuracy_top5* (kanan bawah) menunjukkan nilai yang konstan sepanjang proses pelatihan sebesar 1.0. Ini menunjukkan bahwa model selalu dapat memberikan label

yang tepat untuk lima prediksi teratas dan menunjukkan bahwa model sangat andal untuk tugas klasifikasi yang sederhana.

4. Evaluasi Model

Pada setelah proses pelatihan, performa model dievaluasi dengan menggunakan data *train* yang telah dipisahkan sebelumnya. Tujuan dari langkah ini adalah untuk menghitung berbagai metrik kinerja model, termasuk *precision*, *recall*, dan *F1-score*. Nilai-nilai ini dihitung dengan menggunakan *confusion matrix* yang dihasilkan dari hasil pengujian model pada data *test*.



Gambar 7. Confusion Matrix

Proses dimulai dengan mengambil *confusion matrix* dari hasil pelatihan model yang disimpan dalam variabel *result.confusion_matrix.matrix*. *Confusion matrix* ini memberikan informasi mengenai jumlah prediksi yang benar dan salah untuk setiap kelas sampah, yaitu plastik, kaca, kardus, dan logam. Metrik yang dihitung berdasarkan *matrix* ini meliputi:

- True Positives* (TP): Jumlah prediksi yang benar untuk setiap kelas.
- False Positives* (FP): Jumlah prediksi yang salah, yaitu ketika model mengklasifikasikan kelas lain sebagai kelas yang dimaksud.
- False Negatives* (FN): Jumlah prediksi yang salah, yaitu ketika model salah mengklasifikasikan kelas yang sebenarnya.

Dari nilai-nilai ini, dihitunglah tiga metrik utama untuk setiap kelas:

- Precision*: Mengukur akurasi prediksi positif untuk suatu kelas, dihitung sebagai
$$Precision = \frac{TP}{TP+FP}$$

- b) *Recall*: Mengukur kemampuan model dalam mendeteksi kelas yang benar, dihitung sebagai

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

- c) *F1-score*: Merupakan harmoni antara *precision* dan *recall*, dihitung sebagai

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

Setelah menghitung metrik untuk setiap kelas (plastik, kaca, kardus, logam), rata-rata *precision*, *recall*, dan *F1-score* dihitung untuk memberikan gambaran umum tentang performa model secara keseluruhan.

```

Kaca:
TP: 20
FP: 0
FN: 0
Precision: 1.0
Recall: 1.0
F1-score: 1.0
-----
Kardus:
TP: 20
FP: 0
FN: 0
Precision: 1.0
Recall: 1.0
F1-score: 1.0
-----
Logam:
TP: 19
FP: 1
FN: 1
Precision: 1.0
Recall: 0.95
F1-score: 0.9743589743589743
-----
Plastik:
TP: 20
FP: 0
FN: 0
Precision: 0.9523809523809523
Recall: 1.0
F1-score: 0.9754897548975489
-----
Performa model:
Akurasi: 0.98750001120929
Precision: 0.988952380952381
Recall: 0.9875
F1-score: 0.987492126141219
    
```

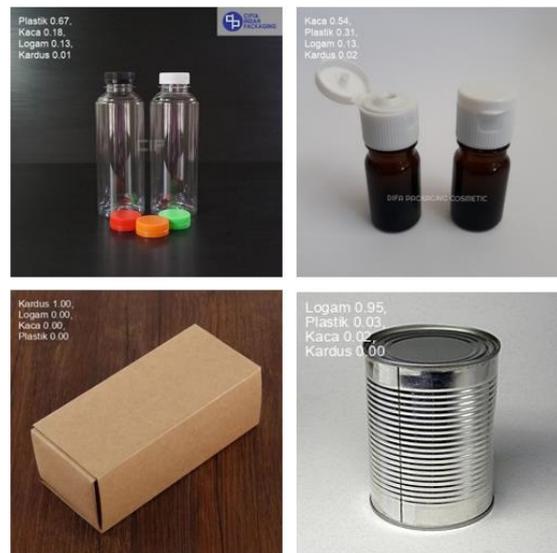
Gambar 8. Hasil Evaluasi Model

Berdasarkan hasil evaluasi model pada gambar 8 dapat dijelaskan sebagai berikut:

- Precision* yang didapat dari masing-masing kelas: Kaca 1.0, Kardus 1.0, Logam 1.0, dan Plastik 0.95.
- Recall* yang didapat dari masing-masing kelas: Kaca 1.0, Kardus 1.0, Logam 0.95, dan Plastik 1.0.
- F1-score* yang didapat dari masing-masing kelas: Kaca 1.0, Kardus 1.0, Logam 0.97, dan Plastik 0.97.
- Secara keseluruhan didapat: Akurasi 0.987, *Precision* 0.988, *Recall* 0.987, dan *F1-score* 0.987

5. Pengujian Model

Setelah melakukan evaluasi pada model, model diuji menggunakan gambar dari luar setelah melakukan evaluasi pada model. Contohnya adalah gambar yang diambil dari *URL* eksternal, seperti yang disebutkan sebelumnya. Tujuan dari pengujian eksternal ini adalah untuk mengevaluasi kemampuan model untuk menggeneralisasi pada data yang tidak ada dalam *dataset* pelatihan dan uji. Hasil pengujian ini akan memberikan bukti lebih lanjut tentang akurasi model saat menangani data yang beragam dan tidak terduga.



Gambar 9. Hasil Pengujian Model

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi sampah daur ulang berbasis citra menggunakan YOLO11, yang dilatih menggunakan dataset citra sampah daur ulang melalui tahapan pengumpulan data dari bank sampah Dewi Sri, *preprocessing* berupa *resizing* dan *split data* untuk pelatihan dan pengujian. Model yang dihasilkan menunjukkan performa sangat baik dengan akurasi keseluruhan sebesar 98,75%. Selain itu, *precision* rata-rata model mencapai 0,988, *recall* sebesar 0,9875, dan *F1-score* sebesar 0,987. Visualisasi hasil pelatihan, seperti grafik *train/loss* dan *val/loss*, menunjukkan konsistensi pembelajaran dan generalisasi model. Uji kemampuan model terhadap data yang tidak termasuk dalam *dataset* pelatihan dan pengujian juga menunjukkan hasil yang signifikan yaitu model mampu menggeneralisasi pola dan karakteristik sampah dengan baik dan mempertahankan akurasi yang tinggi. Hal ini membuktikan bahwa model YOLO11 yang dikembangkan memiliki potensi untuk diterapkan dalam situasi nyata, seperti mendukung pengelolaan sampah daur ulang secara otomatis dan efisien.

V. REFERENSI

- Alwanda, Muhammad Rafly, Raden Putra Kurniawan Ramadhan, dan Derry Alamsyah. 2020. "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle." *Jurnal Algoritme* 1 (1): 45-56. <https://doi.org/10.35957/algorithm.v1i1.434>.

- Aprilino, Awan, dan Imam Husni Al Amin. 2022. "Implementasi Algoritma Yolo Dan Tesseract Ocr Pada Sistem Deteksi Plat Nomor Otomatis." *Jurnal Teknoinfo* 16 (1): 54-59. <https://doi.org/10.33365/jti.v16i1.1522>.
- Ardiansyah, M F, dan P Rosyani. 2023. "Perancangan UI/UX Aplikasi Pengolahan Limbah Anorganik Menggunakan Metode Design Thinking." *LOGIC: Jurnal Ilmu Komputer dan Pendidikan* 1 (4): 839-53. <https://journal.mediapublikasi.id/index.php/logic/article/view/2193>.
- Bahagia, Grace Aprisia, dan Mutaqin Akbar. 2024. "KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)" 8 (5): 10349-55.
- Budiyanta, Nova Eka, Melisa Mulyadi, dan Harlianto Tanudjaja. 2021. "Sistem Deteksi Kemurnian Beras berbasis Computer Vision dengan Pendekatan Algoritma YOLO." *Jurnal Informatika: Jurnal Pengembangan IT* 6 (1): 51-55. <https://doi.org/10.30591/jpit.v6i1.2309>.
- Hasibuan, Muhammad Rasyid Redha. 2023. "Manfaat Daur Ulang Sampah Organik Dan Anorganik Untuk Kesehatan Lingkungan." *Jurnal ilmiah lingkungan* 2 (3): 1-11.
- Iskandar Mulyana, Dadang, dan M Ainur Rofik. 2022. "Implementasi Deteksi Real Time Klasifikasi Jenis Kendaraan Di Indonesia Menggunakan Metode YOLOV5." *Jurnal Pendidikan Tambusai* 6 (3): 13971-82. <https://doi.org/10.31004/jptam.v6i3.4825>.
- Leonardo, Leonardo, Yohannes Yohannes, dan Ery Hartati. 2020. "Klasifikasi Sampah Daur Ulang Menggunakan Support Vector Machine Dengan Fitur Local Binary Pattern." *Jurnal Algoritme* 1 (1): 78-90. <https://doi.org/10.35957/algoritme.v1i1.440>.
- Liunanda, Christopher Nathanel, Silvia Rostianingsih, dan Anita Nathania Purbowo. 2020. "Implementasi Algoritma YOLO pada Aplikasi Pendeteksi Senjata Tajam di Android." *Jurnal Infra* 8:1-7.
- Nafis Alfarizi, Dzaky, Rio Agung Pangestu, Dimas Aditya, Muhammad Adi Setiawan, dan Perani Rosyani. 2023. "Penggunaan Metode YOLO Pada Deteksi Objek: Sebuah Tinjauan Literatur Sistematis." *Jurnal Artificial Intelligent dan Sistem Penunjang Keputusan* 1 (1): 54-63. <https://jurnalmahasiswa.com/index.php/aidanspk>.
- Rahma, Lusiana, Hadi Syaputra, A.Haidar Mirza, dan Susan Dian Purnamasari. 2021. "Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Only Look Once)." *Jurnal Nasional Ilmu Komputer* 2 (3): 213-32. <https://doi.org/10.47747/jurnalnik.v2i3.534>.
- Sandi, Kartiko Mustafi, Abi Prima Yudha, Nanda Dimas Aryanto, dan Mahatamtama Arya Farabi. 2022. "Klasifikasi sampah menggunakan Convolutional Neural Network" 3 (2): 72-81.
- Saputra, Achmad Zaky, dan Ah. Sulhan Fauzi. 2022. "Pengolahan Sampah Kertas Menjadi Bahan Baku Industri Kertas Bisa Mengurangi Sampah di Indonesia." *Jurnal Mesin Nusantara* 5 (1): 41-52. <https://doi.org/10.29407/jmn.v5i1.17522>.
- Saputra, Reyhan Adi, Davito Rasendriya Rizqullah Putra, dan Muhammad Alaika Asyrofi. 2023. "Implementasi Convolutional Neural Network (Cnn) Untuk Mendeteksi Penggunaan Masker Pada Gambar." *Jurnal Informatika dan Teknik Elektro Terapan* 11 (3): 710-14. <https://doi.org/10.23960/jitet.v11i3.3286>.
- Wahyudinata, Adjie, dan Harya Bima Dirgantara. 2020. "Pengembangan Gim Edukasi 2D Pemilahan Sampah Daur Ulang Berbasis Android." *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer* 20 (1): 129-38. <https://doi.org/10.30812/matrik.v20i1.860>.