

Model Pembeda Sampah Organik dan Anorganik dengan *Machine Learning* berbasis *Phyton*

DOI: <http://dx.doi.org/10.35889/jutisi.v14i3.3182>

Creative Commons License 4.0 (CC BY – NC)

Ika Aprillia¹, Budi Rahmani^{2*}

Teknik Informatika, STMIK Banjarbaru, Banjarbaru, Indonesia

*Email Corresponding Author: budirahmani@gmail.com

Abstract

This research developed an artificial intelligence-based system to differentiate between organic and inorganic waste using a Convolutional Neural Network (CNN) model. The problem addressed is the community's limited understanding of how to properly separate types of waste, which contributes to environmental pollution. The methodology employed includes data collection of waste images, training the CNN model, and system testing. The test results showed that the model achieved an accuracy of 75%, with a precision of 78% and a recall of 70%. These findings suggest that the developed system can help the community better understand and separate waste more effectively. This research makes a positive contribution to waste management and is expected to serve as a foundation for further development in waste classification technology.

Keywords: Artificial intelligence; Convolutional Neural Network; Waste separation; Environmental management; Machine learning

Abstrak

Penelitian ini mengembangkan sistem berbasis kecerdasan buatan untuk membedakan sampah organik dan anorganik menggunakan model *Convolutional Neural Network* (CNN). Permasalahan yang dihadapi adalah rendahnya pemahaman masyarakat dalam memisahkan jenis sampah, yang berdampak pada pencemaran lingkungan. Metodologi yang digunakan meliputi pengumpulan data gambar sampah, pelatihan model CNN, dan pengujian sistem. Hasil pengujian menunjukkan bahwa model mencapai akurasi 75%, dengan presisi 78% dan *recall* 70%. Temuan ini menunjukkan bahwa sistem yang dikembangkan dapat membantu masyarakat dalam memahami dan memisahkan sampah dengan lebih baik. Penelitian ini memberikan kontribusi positif terhadap pengelolaan sampah dan diharapkan dapat menjadi dasar untuk pengembangan lebih lanjut dalam teknologi klasifikasi sampah.

Kata kunci: Kecerdasan buatan; *Convolutional Neural Network*; Pemisahan sampah; Pengelolaan lingkungan; Machine learning

1. Pendahuluan

Pengelolaan sampah menjadi isu krusial di negara berkembang seperti Indonesia [1]. Berdasarkan data Badan Pusat Statistik (2023), Indonesia menghasilkan sekitar 68 juta ton sampah setiap tahun, namun hanya 60% yang dikelola dengan baik. Ketidakefisienan ini menimbulkan dampak serius terhadap lingkungan, kesehatan, dan ekosistem. Pemisahan sampah organik dan anorganik merupakan langkah penting untuk meningkatkan efisiensi pengelolaan sampah [1].

Sayangnya, masih banyak masyarakat yang kesulitan dalam membedakan jenis sampah. Survei yang dilakukan pada 3 November 2024 di Lapangan Murjani, Banjarbaru, menunjukkan bahwa 60% responden berpendidikan sekolah dasar tidak mampu membedakan sampah organik dan anorganik. Rendahnya literasi pengelolaan sampah ini memerlukan solusi inovatif.

Penelitian sebelumnya menunjukkan bahwa teknologi kecerdasan buatan, seperti *Convolutional Neural Network* (CNN), mampu mengklasifikasikan gambar sampah secara

otomatis [1][2][4]–[7]. Namun, sebagian besar penelitian masih terbatas pada dataset kecil dan belum diimplementasikan secara langsung di masyarakat.

Penelitian ini bertujuan mengembangkan model klasifikasi sampah organik dan anorganik berbasis CNN menggunakan dataset yang lebih besar dan beragam [7]–[9]. Sistem yang dikembangkan diharapkan tidak hanya memiliki akurasi tinggi, tetapi juga mudah digunakan oleh masyarakat, sehingga dapat menjadi solusi praktis untuk mendukung pengelolaan sampah secara berkelanjutan.

2. Tinjauan Pustaka

Penelitian ini mengintegrasikan temuan dari beberapa studi sebelumnya yang berfokus pada klasifikasi sampah menggunakan *Convolutional Neural Network* (CNN) [6][11]–[15]. Berbagai studi telah membuktikan efektivitas CNN dalam pengolahan citra dan pengenalan objek, menjadikannya pilihan ideal untuk klasifikasi sampah. Penelitian yang dilakukan [15] misalnya, menggunakan CNN untuk klasifikasi sampah organik dan anorganik di Indonesia. Dalam penelitiannya, model mencapai akurasi tinggi (96%) untuk sampah non-organik, namun hanya 62% untuk organik, menunjukkan tantangan yang disebabkan oleh keragaman bentuk dan tekstur sampah organik. Demikian pula [5] yang berhasil mencapai akurasi 92% pada data pelatihan dan 79% pada data pengujian untuk mengklasifikasikan berbagai jenis sampah, termasuk kertas, kaca, metal, dan plastik. Penelitian [4] menerapkan arsitektur VGG-16 dan mencapai akurasi 64.33% pada data uji manual, dengan tingkat kesalahan signifikan pada klasifikasi sampah anorganik. Keterbatasan ini sering kali berasal dari dataset yang kurang bervariasi atau spesifik, yang dapat menyebabkan model mengalami *overfitting* dan memiliki kinerja kurang optimal pada skenario dunia nyata.

Pendekatan klasifikasi citra sampah berbasis CNN juga telah didukung oleh penelitian lain yang menunjukkan kekuatan algoritma ini. Penelitian [16] menggunakan CNN untuk lokalisasi dan ekstraksi teks dari gambar, dan [17] memberikan tinjauan mendalam tentang pembelajaran mendalam melalui CNN [12]. Selain itu, teknologi pemrosesan citra digital dan jaringan saraf tiruan juga telah diterapkan dalam domain lain, seperti prediksi bahan organik dalam tanah, pengenalan tulisan tangan, dan deteksi benda [19][20]. Penggunaan kecerdasan buatan untuk robot beroda juga telah dikembangkan, yang relevan untuk aplikasi pemilahan sampah otomatis [9]. Studi lain menunjukkan implementasi CNN dalam mendeteksi objek dengan akurasi yang tinggi, seperti pengenalan digit [10], dan identifikasi teks dengan berbagai bentuk [11].


Dengan adanya kekurangan dan tantangan pada penelitian sebelumnya, seperti yang diidentifikasi oleh [3], penelitian ini bertujuan untuk menyempurnakan solusi yang sudah ada. Kebaruan dari penelitian ini terletak pada integrasi model klasifikasi gambar berbasis CNN dengan pendekatan antarmuka yang ramah pengguna, sehingga berpotensi meningkatkan partisipasi publik dalam pemisahan sampah. Sistem ini dirancang agar dapat dilatih dan diuji secara langsung serta mudah digunakan oleh masyarakat luas melalui sebuah website.

3. Metodologi

Penelitian ini merupakan riset eksperimental yang bertujuan untuk membangun dan menguji sistem klasifikasi sampah organik dan anorganik berbasis *Convolutional Neural Network* (CNN)[8]. Fokus utama adalah merancang alur kerja komputasi dari proses pelatihan hingga pengujian model dengan dataset gambar sampah yang dikurasi secara purposif.

3.1. Prosedur dan Tahapan Penelitian

Flowchart pada *Gambar 1* menggambarkan tahapan prosedur penelitian dalam pengembangan sistem klasifikasi sampah berbasis CNN secara runtut dan menyeluruh. Proses diawali dengan pengumpulan dataset sebanyak 100 gambar sampah organik dan anorganik, kemudian dilakukan *preprocessing* seperti *resize* dan normalisasi piksel, serta pembagian data menjadi data latih dan data uji. Selanjutnya, model CNN dilatih menggunakan *TensorFlow* dan *Keras* dengan arsitektur yang mencakup *convolutional layer*, *pooling*, *flatten*, dan *dense layer* dengan aktivasi *softmax*. Setelah pelatihan, pengguna dapat menguji sistem melalui antarmuka dengan memilih gambar uji, dan hasil klasifikasi ditampilkan secara *real-time*. *Flowchart* ini memberikan gambaran visual yang jelas mengenai alur pengembangan sistem klasifikasi sampah menggunakan CNN.



Gambar 1. Tahapan Penelitian

3.2. Model Arsitektur *Convolutional Neural Network* (CNN)

Berikut adalah detail arsitektur model ***Convolutional Neural Network* (CNN)** yang digunakan untuk klasifikasi sampah organik dan anorganik. Model ini dikembangkan menggunakan **TensorFlow** dan **Keras library**, seperti halnya diperlihatkan pada **Tabel 1** dan **Tabel 2**.

1) Deskripsi Lapisan (Layers)

Model ini terdiri dari urutan *standard layers* untuk klasifikasi citra:

Tabel 1. <i>Standard layers</i>		
Layer	Konfigurasi/Fungsi	Detail
Input Layer	Input Shape	Citra di-resize ke 150×150 piksel
Convolutional Layer	Kernel Size	3×3
Pooling Layer	Type	Max Pooling
Flatten Layer	Function	Mengubah <i>feature map</i> menjadi vektor 1D
Dense Layer	Output Layer	Dense Layer dengan fungsi aktivasi Softmax

2) Parameter Pelatihan (*Training Parameters*)

Model dilatih menggunakan parameter berikut:

Tabel 2. Parameter pelatihan CNN

Parameter	Nilai yang Digunakan
Epoch	10–20
Batch Size	8/16
Optimizer	Adam
Loss Function	Binary Crossentropy
Data Latih (Training Data)	80 gambar (40 organik, 40 anorganik)
Data Uji (Testing Data)	20 gambar (10 organik, 10 anorganik)

Arsitektur CNN yang digunakan dirancang secara sequential. Citra masukan yang telah diproses (*resize* 150×150 piksel dan normalisasi piksel) diproses melalui serangkaian lapisan *convolutional* (3×3) dan max pooling untuk mengekstraksi fitur visual. Fitur yang diekstraksi kemudian diratakan (*flatten*) menjadi vektor 1D sebelum dimasukkan ke lapisan dense. Lapisan *output* menggunakan fungsi aktivasi Softmax untuk menghasilkan probabilitas klasifikasi akhir antara sampah organik dan anorganik.

3.3. Mekanisme Pengujian dan Validasi

Evaluasi model dilakukan dengan pendekatan kuantitatif menggunakan *Confusion Matrix*. Matriks ini menyajikan 4 komponen utama:

- TP (True Positive): Sampah organik yang terdeteksi sebagai organik.
- TN (True Negative): Sampah anorganik yang terdeteksi sebagai anorganik.
- FP (False Positive): Sampah anorganik yang salah terdeteksi sebagai organik.
- FN (False Negative): Sampah organik yang salah terdeteksi sebagai anorganik.

Berdasarkan komponen di atas, dihitung beberapa metrik performa:

1. Accuracy

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \dots\dots\dots (1)$$

2. Precision

$$Precision = \frac{TP}{TP + FP} \dots\dots\dots (2)$$

3. Recall

$$Recall = \frac{TP}{TP + FN} \dots\dots\dots (3)$$

4. F1-Score

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \dots\dots\dots (4)$$

3.4. Analisis Hasil dan Evaluasi

Setelah model selesai dilatih dan diuji, dilakukan interpretasi hasil sebagai berikut:


- Evaluasi Fungsional: Apakah semua fitur antarmuka berfungsi dengan benar, seperti proses pelatihan, pengujian, dan penyajian hasil.
- Evaluasi Akurasi Model: Berdasarkan hasil *Confusion Matrix*, dilakukan penilaian keberhasilan model terhadap data uji.

4. Hasil dan Pembahasan

4.1. Hasil Implementasi Sistem

Penelitian ini telah menghasilkan sistem klasifikasi sampah berbasis *Convolutional Neural Network* (CNN) yang dapat membedakan antara sampah organik dan anorganik melalui proses pelatihan dan pengujian. Implementasi sistem dilakukan dalam bentuk aplikasi berbasis GUI menggunakan *Tkinter*, dengan beberapa antarmuka yang menunjukkan proses dari pemilihan data latih, pelatihan model, hingga pengujian gambar.

4.1.1. Tampilan Awal Sistem



Gambar 2. Tampilan Awal Sistem

Gambar 2 menunjukkan antarmuka awal sistem yang sederhana dan intuitif. Pengguna dapat mengakses tombol untuk memulai proses pelatihan maupun pengujian melalui tampilan utama ini.

4.1.2. Tampilan Proses Pelatihan


Sebelum melihat proses pelatihan, maka berikut adalah contoh citra untuk keperluan pelatihan dan juga pengujian dari model yang dibangun. Masing-masing secara berurutan ditampilkan pada Gambar 3, Gambar 4, Gambar 5, dan Gambar 6. Kemudian Gambar 3 ini menampilkan berbagai jenis objek organik seperti sisa makanan, daun, buah-buahan busuk, atau material biodegradable lainnya. Citra-citra ini digunakan sebagai data pelatihan untuk melatih model kecerdasan buatan agar mampu mengenali dan mengklasifikasikan objek organik secara akurat. Kualitas dan variasi citra sangat penting untuk memastikan model dapat mengenali objek organik dalam berbagai kondisi pencahayaan, sudut pandang, dan latar belakang.




Gambar 3. Citra Sampel Objek Organik Untuk Pelatihan Sistem/Model

Selanjutnya Gambar 4 berisi contoh-contoh objek anorganik seperti plastik, logam, kaca, dan bahan-bahan yang tidak mudah terurai. Citra-citra ini digunakan dalam proses pelatihan model untuk membedakan antara objek organik dan anorganik. Keberagaman jenis dan bentuk objek anorganik dalam citra membantu meningkatkan kemampuan generalisasi model terhadap data dunia nyata. Kemudian Gambar 5 digunakan sebagai bagian dari dataset pengujian, berisi objek organik yang belum pernah dilihat oleh model selama pelatihan. Tujuannya adalah untuk mengevaluasi seberapa baik model dapat mengidentifikasi objek organik secara akurat di luar data pelatihan. Pengujian ini penting untuk menilai performa dan keandalan sistem dalam situasi nyata. Terakhir, Gambar 6 berisi objek anorganik yang digunakan dalam tahap pengujian sistem.


Citra-citra ini membantu mengukur kemampuan model dalam mengenali dan mengklasifikasikan objek anorganik secara konsisten. Evaluasi terhadap citra ini memberikan gambaran tentang akurasi dan presisi model dalam membedakan jenis sampah atau objek berdasarkan karakteristik visualnya.



Gambar 4. Citra Sampel Citra Objek Nanorganik Untuk Pelatihan Sistem/Model




Gambar 5. Citra Sampel Citra Objek Organik Untuk Pengujian Sistem/Model




Gambar 6. Citra Sampel Citra Objek Anorganik Untuk Pengujian Sistem/Model


Selanjutnya **Gambar 7**, **Gambar 8**, **Gambar 9**, dan **Gambar 10** secara berurutan menunjukkan proses pelatihan yang dimulai dengan memilih folder data latih, yang berisi 80 gambar (40 organik, 40 anorganik). Saat pelatihan dimulai, terminal akan menampilkan informasi seperti jumlah data, jumlah epoch, akurasi, dan nilai loss. Berikut adalah ringkasan akurasi pada beberapa epoch:




Gambar 7. Tampilan window pelatihan



Gambar 8. Tampilan Window Pemilihan Folder File Pelatihan



Gambar 9. Tampilan *Window* Pasca Pemilihan Folder File Pelatihan




Gambar 10. Tampilan *Window* Setelah Proses Pelatihan

Tabel 3. Ringkasan Akurasi Pada Beberapa Epoch


Epoch	Accuracy	Loss
1	39.58%	2.4294
10	58.33%	1.1802
20	69.53%	0.5467

Akurasi meningkat signifikan dari awal pelatihan hingga akhir, yang menunjukkan proses pembelajaran oleh model berjalan baik, hal ini ditunjukkan pada Tabel 3. Secara grafik bisa dilihat pada




Gambar 11. Tampilan *Window* Setelah Proses Pelatihan

4.1.3. Tampilan Proses Pengujian



Gambar 12. Tampilan *Window* Untuk Proses Pengujian



Gambar 13. Tampilan *Window* Untuk Pemilihan File Untuk Proses Pengujian



Gambar 14. Tampilan *Window* Untuk Proses Pengujian Gambar Tertentu 1



Gambar 15. Tampilan *Window* Hasil Pengujian Gambar Tertentu 1

Gambar 12, Gambar 13, Gambar 14 dan Gambar 15 menunjukkan proses pengujian yang dilakukan dengan memilih satu gambar uji secara manual dan menekan tombol "Mulai Pengujian". Hasil klasifikasi ditampilkan secara *real-time*. Misalnya, sistem berhasil memprediksi bahwa "Gambar Uji anorganik (1).jpg" adalah sampah anorganik.

Pada Tabel 4 dan Tabel 5 ditunjukkan hasil pengujian kali ini, sistem diuji untuk mengenali sampah organik dan anorganik melalui 20 gambar, yang terdiri dari 10 gambar sampah organik dan 10 gambar sampah anorganik. Dari 10 gambar sampah organik, sistem berhasil memprediksi dengan benar 7 gambar (70%). Namun, terdapat 3 kesalahan prediksi

(30%) di mana sampah organik terdeteksi sebagai anorganik. Prediksi yang salah terjadi pada gambar ke-2, ke-5, dan ke-10, yang seharusnya termasuk sampah organik namun malah teridentifikasi sebagai sampah anorganik.

Tabel 4. Hasil Pengujian Sampah Organik

CITRA ORGANIK KE-	HASIL PREDIKSI SISTEM	KETERANGAN
1	Organik	Benar
2	Non Organik	Salah
3	Organik	Benar
4	Non Organik	Benar
5	Organik	Salah
6	Non Organik	Benar
7	Organik	Benar
8	Non Organik	Salah
9	Organik	Benar
10	Non Organik	Salah

Kesalahan prediksi ini kemungkinan disebabkan oleh beberapa faktor, seperti:

1. Kesamaan Visual: Beberapa jenis sampah organik, seperti daun yang sudah mulai kering atau kulit buah yang terkelupas, bisa tampak mirip dengan sampah anorganik. Hal ini mungkin menyulitkan sistem dalam membedakan keduanya secara tepat.
2. Kualitas Gambar: Jika gambar memiliki pencahayaan yang kurang baik atau resolusi rendah, fitur visual yang diperlukan untuk identifikasi bisa tidak terlihat jelas.
3. Variasi Sampah Organik: Jika dataset yang digunakan untuk melatih sistem tidak cukup beragam dalam mencakup berbagai jenis sampah organik, sistem mungkin kesulitan mengenali variasi tersebut.

Untuk memastikan bahwa langkah-langkah strategis yang direkomendasikan dalam penelitian ini benar-benar efektif dan dapat diterapkan secara praktis, maka setiap butir rekomendasi didukung oleh hasil-hasil penelitian terdahulu sebagai benchmark ilmiah:

1) Peningkatan Dataset

Penambahan jumlah dan variasi citra dalam dataset pelatihan terbukti meningkatkan akurasi model klasifikasi. Penelitian [15] menunjukkan bahwa model CNN yang dilatih dengan dataset yang lebih beragam mampu mencapai akurasi hingga 96% untuk sampah anorganik, meskipun hanya 62% untuk sampah organik. Hal ini menunjukkan bahwa keberagaman data sangat penting untuk meningkatkan kemampuan generalisasi model.

2) Pengolahan Citra Lanjut

Teknik pra-pemrosesan seperti normalisasi piksel, augmentasi citra, dan peningkatan kualitas gambar telah terbukti meningkatkan akurasi klasifikasi. Penelitian [5] melaporkan bahwa pencahayaan dan resolusi gambar yang baik dapat meningkatkan akurasi hingga 92% pada data pelatihan. Teknik augmentasi juga membantu model mengenali objek dalam berbagai kondisi visual.

3) Latihan dengan Dataset yang Lebih Luas

Penelitian [3] dan [4] menunjukkan bahwa penggunaan arsitektur CNN seperti VGG-16 dan ResNet pada dataset yang lebih besar dan kompleks dapat meningkatkan akurasi klasifikasi. Meskipun VGG-16 hanya mencapai akurasi 64.33% pada data uji manual, model ini menunjukkan potensi besar jika dikombinasikan dengan dataset yang luas dan teknik regularisasi yang tepat.

4) Evaluasi Berbasis *Confusion Matrix*

Penggunaan confusion matrix sebagai alat evaluasi memberikan gambaran yang komprehensif terhadap kinerja sistem. Penelitian [11] dan [17] menekankan bahwa metrik seperti presisi, *recall*, dan *F1-score* sangat penting untuk menilai efektivitas model klasifikasi, terutama dalam konteks pengenalan objek yang kompleks seperti sampah organik dan non-organik.

Dengan merujuk pada hasil-hasil penelitian tersebut, strategi yang dikemukakan dalam studi ini tidak hanya bersifat teoritis, tetapi juga telah terbukti secara empiris dalam berbagai studi sebelumnya. Hal ini memperkuat validitas dan efektivitas pendekatan yang digunakan dalam pengembangan sistem klasifikasi citra sampah berbasis CNN.

Tabel 5. Hasil Pengujian Sampah Anorganik

CITRA NON ORGANIK KE-	HASIL SISTEM	KETERANGAN
1	Non Organik	Benar
2	Non Organik	Benar
3	Organik	Salah
4	Non Organik	Benar
5	Non Organik	Benar
6	Organik	Salah
7	Non Organik	Benar
8	Non Organik	Benar
9	Organik	Benar
10	Non Organik	Benar

Untuk sampah anorganik, sistem berhasil memprediksi dengan benar 8 gambar (80%), sementara 2 kesalahan prediksi (20%) terjadi pada gambar ke-3 dan ke-6, di mana sampah non-organik salah dikenali sebagai sampah organik. Kesalahan dalam pengenalan sampah non-organik bisa disebabkan oleh beberapa faktor:

- Pengaruh Warna dan Tekstur: Sampah anorganik, seperti plastik atau logam, sering kali memiliki warna dan tekstur yang sangat khas. Namun, dalam beberapa kondisi, seperti tumpang tindih dengan sampah organik atau adanya refleksi pada permukaan sampah, sistem dapat keliru mengenali sampah tersebut.
- Kualitas Gambar: Jika gambar diambil dengan pencahayaan buruk atau kualitas rendah, fitur-fitur penting pada sampah anorganik yang seharusnya memudahkan identifikasi mungkin tidak terekam dengan baik.
- Bingung dengan Sampah yang Tertutup: Kadang-kadang, sampah anorganik bisa tampak serupa dengan sampah organik jika tertutup atau bercampur dengan bahan organik, menyebabkan sistem membuat kesalahan.

Rekomendasi Perbaikan untuk proses ini adalah:

- Meningkatkan kualitas gambar dan memperbaiki teknik pemrosesan gambar bisa membantu meningkatkan akurasi deteksi sampah anorganik, terutama ketika sampah tersebut bercampur atau tertutup oleh bahan lain.
- Menambah jumlah gambar sampah anorganik dengan kondisi yang lebih bervariasi, serta meningkatkan variasi objek dalam dataset, akan meningkatkan kemampuan sistem dalam mengenali berbagai jenis sampah anorganik.

4.1.4. Analisis Perbandingan Kinerja Pengujian Sampah Organik dan Anorganik

Dari hasil yang diperoleh, terlihat bahwa sistem memiliki akurasi yang lebih baik dalam mengenali sampah anorganik dibandingkan sampah organik. Berikut adalah beberapa poin perbandingan:

1. Akurasi:
 - Sampah Organik: Akurasi sistem pada sampah organik adalah 70%.
 - Sampah anorganik: Akurasi sistem pada sampah anorganik adalah 80%.
2. Kesalahan Prediksi:
 - Untuk sampah organik, sistem membuat 3 kesalahan dari 10 gambar.
 - Untuk sampah anorganik, hanya ada 2 kesalahan dari 10 gambar.
3. Dampak Kesalahan:
 - Kesalahan pada sampah organik dapat mengarah pada kesalahan dalam proses pemilahan sampah, yang bisa memengaruhi efisiensi daur ulang.
 - Kesalahan pada sampah anorganik dapat mempengaruhi pengelolaan sampah, terutama dalam hal pemilahan bahan yang dapat didaur ulang.

Tabel 6. Confusion Matrix

	Prediksi Organik	Prediksi Non Organik
Sebenarnya Organik	7 (TP)	3 (FN)
Sebenarnya Anorganik	2 (FP)	8 (TN)

Tabel . Menunjukkan *Confusion Matrix* dan secara umum artinya:

- TP (True Positive): 7 gambar sampah organik yang benar teridentifikasi sebagai organik.
- TN (True Negative): 8 gambar sampah anorganik yang benar teridentifikasi sebagai anorganik.
- FP (False Positive): 2 gambar sampah anorganik yang salah teridentifikasi sebagai sampah organik.
- FN (False Negative): 3 gambar sampah organik yang salah teridentifikasi sebagai sampah anorganik.

Berdasarkan *confusion matrix*, berikut adalah metrik evaluasi yang dihitung untuk menilai kinerja sistem:

$$\text{Akurasi} = (TP + TN) / \text{Total} = (7 + 8) / 20 = 75\%$$

$$\text{Presisi} = TP / (TP + FP) = 7 / (7 + 2) = 78\%$$

$$\text{Recall} = TP / (TP + FN) = 7 / (7 + 3) = 70\%$$

$$\text{F1-Score} = 2 \times (\text{Presisi} \times \text{Recall}) / (\text{Presisi} + \text{Recall}) \approx 73,8\%$$

Berdasarkan perhitungan metrik evaluasi di atas, kita dapat menarik beberapa kesimpulan tentang kinerja sistem ini:

- Akurasi (75%) menunjukkan bahwa sistem cukup baik dalam memprediksi jenis sampah secara keseluruhan. Namun, angka ini tidak cukup tinggi untuk menjamin sistem sangat efisien dalam mengenali setiap jenis sampah secara individu.
- Presisi (78%) menunjukkan bahwa dari seluruh sampah yang diprediksi sebagai organik, 78% benar-benar organik. Ini adalah angka yang cukup baik, namun masih ada ruang untuk meningkatkan ketepatan sistem dalam meminimalkan *false positives*.
- *Recall* (70%) mengindikasikan bahwa sistem masih mengalami kesulitan dalam mengenali seluruh sampah organik yang ada. Meskipun sistem berhasil mengenali sebagian besar sampah organik, 30% dari sampah organik masih terlewatkan, yang dapat berdampak pada pengelolaan sampah yang lebih efisien.
- F1-Score (73,8%) menunjukkan bahwa meskipun presisi dan recall masih memiliki beberapa kekurangan, sistem memiliki keseimbangan yang cukup baik antara keduanya. Namun, masih ada potensi perbaikan terutama pada recall untuk lebih banyak mengenali sampah organik.

4.1.1. Rekomendasi untuk Peningkatan Sistem (Diperkuat dengan Benchmark Penelitian)

Berdasarkan hasil evaluasi melalui *confusion matrix*, sistem menunjukkan performa yang cukup baik dengan akurasi sebesar 75%, presisi 78%, *recall* 70%, dan F1-score 73,8%. Namun, angka *recall* yang relatif lebih rendah menunjukkan bahwa sistem masih memiliki tantangan dalam mengenali seluruh sampah organik secara konsisten. Oleh karena itu, beberapa rekomendasi berikut diajukan untuk meningkatkan kinerja sistem secara menyeluruh:

1) Meningkatkan *Recall* melalui Diversifikasi Dataset

Recall yang rendah sering kali disebabkan oleh keterbatasan variasi dalam data pelatihan. Untuk mengatasi hal ini, disarankan agar dataset diperkaya dengan lebih banyak gambar sampah organik dalam berbagai kondisi—misalnya, sampah yang telah terdegradasi, tercampur dengan bahan lain, atau memiliki tekstur yang tidak umum. Penelitian oleh [15] menunjukkan bahwa model CNN yang dilatih dengan dataset yang lebih beragam mampu meningkatkan akurasi klasifikasi secara signifikan, terutama untuk kategori yang kompleks seperti sampah organik.

2) Peningkatan Kualitas Gambar dan Teknik Pra-pemrosesan

Kualitas citra sangat memengaruhi kemampuan sistem dalam mengenali fitur visual penting. Gambar dengan pencahayaan buruk atau resolusi rendah dapat menyebabkan hilangnya detail yang krusial. Oleh karena itu, penggunaan teknik pra-pemrosesan seperti normalisasi piksel, peningkatan kontras, dan pengurangan noise sangat dianjurkan. Penelitian [5] membuktikan bahwa peningkatan kualitas gambar dapat mendorong akurasi hingga 92% dalam klasifikasi citra sampah.

3) Penggunaan Arsitektur Model yang Lebih Canggih

Model CNN yang lebih kompleks seperti ResNet, MobileNet, atau EfficientNet memiliki kemampuan representasi fitur yang lebih dalam dan efisien. Penelitian [3] dan [4] menunjukkan bahwa penggunaan arsitektur VGG-16 dan ResNet dapat meningkatkan

akurasi klasifikasi, terutama ketika dikombinasikan dengan dataset yang luas dan teknik regularisasi yang tepat.

Meskipun sistem yang dikembangkan telah menunjukkan performa yang menjanjikan, tantangan utama yang perlu diperhatikan adalah bagaimana sistem dapat lebih sensitif terhadap variasi sampah organik yang kompleks. Sampah organik memiliki bentuk, warna, dan tekstur yang sangat beragam, sehingga membutuhkan pendekatan yang lebih adaptif dalam pelatihan model. Langkah-langkah yang direkomendasikan di atas bukan hanya bersifat teknis, tetapi juga mencerminkan kebutuhan untuk memahami konteks visual secara lebih mendalam. Dengan memperkaya data, meningkatkan kualitas input, dan memilih arsitektur yang tepat, sistem ini tidak hanya akan lebih akurat, tetapi juga lebih inklusif terhadap kondisi nyata di lapangan.

Harapannya, sistem ini dapat menjadi alat bantu yang efektif bagi masyarakat dalam memilah sampah secara mandiri, sekaligus mendukung upaya pengelolaan lingkungan yang lebih berkelanjutan. Dengan dukungan dari hasil-hasil penelitian sebelumnya, rekomendasi ini memiliki landasan ilmiah yang kuat dan layak untuk dijadikan arah pengembangan sistem di masa mendatang.

5. Simpulan

Penelitian ini berhasil mengembangkan sistem klasifikasi sampah organik dan anorganik berbasis *Convolutional Neural Network* (CNN) yang mampu mengenali jenis sampah dari citra gambar dengan akurasi sebesar 75%, presisi 78%, dan *recall* 70%. Hasil ini menunjukkan bahwa model yang dibangun cukup efektif dalam membedakan antara dua kategori sampah utama, meskipun masih terdapat ruang untuk peningkatan terutama dalam aspek *recall* terhadap sampah organik. Penggunaan dataset yang terbatas menjadi salah satu faktor pembatas kinerja model, sehingga pengembangan lebih lanjut dengan dataset yang lebih besar dan bervariasi sangat direkomendasikan untuk meningkatkan generalisasi dan keandalan sistem. Penelitian ini tidak hanya menjawab tujuan utama untuk menciptakan sistem klasifikasi otomatis, tetapi juga memberikan kontribusi nyata terhadap upaya peningkatan kesadaran masyarakat dalam pengelolaan sampah. Dengan adanya sistem ini, masyarakat diharapkan lebih teredukasi dalam pemisahan sampah dan berkontribusi pada pengurangan pencemaran lingkungan serta peningkatan efisiensi proses daur ulang. Ke depan, pengembangan dapat diarahkan pada penerapan teknologi ini di lingkungan nyata, penerapan teknik augmentasi data untuk meningkatkan akurasi model, serta penguatan aspek edukatif melalui program pelatihan kepada masyarakat. Penelitian ini juga membuka peluang bagi riset lanjutan di bidang pengolahan citra dan kecerdasan buatan untuk mendukung pengelolaan lingkungan secara lebih cerdas dan berkelanjutan.

Daftar Referensi

- [1] L. Harmaji and Khairullah, "Rancang Bangun Tempat Pemilahan Sampah Logam dan Non Logam Otomatis Berbasis Mikrokontroler," *Progresif J. Ilm. Komput.*, vol. 15, no. 2, pp. 73–82, 2019.
- [2] A. Ikhlas and B. Hendrik, "Literature Review: A Comparative Study of Waste Classification using Deep Learning Algorithms," *Sist. J. Sist. Inf.*, vol. 14, no. 3, p. 1360, 2025, doi: 10.32520/stmsi.v14i3.5163.
- [3] F. Tanadi, *Implementasi Convolutional Neural Network dalam Sistem Klasifikasi Gambar Sampah Berbasis Website*, Skripsi, Universitas Multimedia Nusantara, 2023.
- [4] A. Tia Sari, E. Nurlatifah, T. Informatika, and U. Sunan Gunung Djati Bandung, "Penerapan Convolutional Neural Network untuk Mengklasifikasikan Citra Sampah Organik dan Non Organik," *J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 14, pp. 1–11, 2025.
- [5] K. M. Sandi, A. P. Yudha, N. D. Aryanto, and M. A. Farabi, "Klasifikasi Sampah di Saluran Air Menggunakan Algoritma CNN," *Indones. J. Data Sci.*, vol. 3, no. 2, pp. 72–81, 2022, doi: 10.56705/ijodas.v3i2.33.
- [6] A. Kurniawan and S. Maesaroh, *Pengklasifikasian Citra Sampah Organik dan Anorganik Menggunakan Algoritma Convolutional Neural Network*, Artikel, 2023.
- [7] M. A. Kalam, M. N. I. Mondal, and B. Ahmed, "Rotation Independent Digit Recognition in Sign Language," in *Proc. Int. Conf. Electr., Comput. Commun. Eng. (ECCE)*, 2019, pp. 1–5, doi: 10.1109/ECACE.2019.8679172.

- [8] A. N. Alhawsawi, S. D. Khan, and F. Ur Rehman, "Crowd Counting in Diverse Environments Using a Deep Routing Mechanism Informed by Crowd Density Levels," *Information*, vol. 15, no. 5, pp. 1–22, 2024, doi: 10.3390/info15050275.
- [9] M. Liao, P. Lyu, M. He, C. Yao, W. Wu, and X. Bai, "Mask TextSpotter: An End-to-End Trainable Neural Network for Spotting Text with Arbitrary Shapes," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 43, no. 2, pp. 532–548, 2019, doi: 10.1109/TPAMI.2019.2937086.
- [10] S. Gaikwad *et al.*, "Deep Learning Framework for Precision Grading and Non-Invasive Apple Sweetness Evaluation," *Polish Marit. Res.*, vol. 30, no. 3, pp. 48–58, 2023, doi: 10.2478/ijssis-2025-0007.
- [11] M. Fiandero, T. T. Nguyen, H. Wong, and E. B. Hsu, "Modernized Crowd Counting Strategies for Mass Gatherings—A Review," *J. Acute Med.*, vol. 13, no. 1, pp. 4–11, 2023, doi: 10.6705/j.jacme.202303_13(1).0002.
- [12] S. Gaikwad and S. Kothari, "Deep Learning Framework for Precision Grading and Non-Invasive Apple Sweetness Evaluation," *Int. J. Smart Sens. Intell. Syst.*, vol. 18, no. 1, 2025, doi: 10.2478/ijssis-2025-0007.
- [13] R. Dikairono, S. Setiawardhana, D. Purwanto, and T. A. Sardjono, "CNN-Based Self Localization Using Visual Modelling of a Gyrocompass Line Mark and Omni-Vision Image for a Wheeled Soccer Robot Application," *Int. J. Intell. Eng. Syst.*, vol. 13, no. 6, pp. 442–453, 2020, doi: 10.22266/ijies2020.1231.39.
- [14] M. Mathew, M. Jain, and C. V. Jawahar, "Benchmarking Scene Text Recognition in Devanagari, Telugu and Malayalam," in *Proc. 14th IAPR Int. Conf. Document Analysis and Recognition (ICDAR)*, vol. 7, pp. 42–46, 2017, doi: 10.1109/ICDAR.2017.364.
- [15] A. I. Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 1, pp. 142–149, 2022, doi: 10.28932/jutisi.v8i1.4314.
- [16] P. Pattaranuprawat and R. Lipikorn, "Text Localization and Extraction from Background with Texture and Noise in Digital Images Using Adaptive Thresholding and Convolutional Neural Network," in *Proc. 23rd Int. Comput. Sci. Eng. Conf. (ICSEC)*, 2019, pp. 357–360, doi: 10.1109/ICSEC47112.2019.8974808.
- [17] P. Kalange and M. Mutalikdesai, "Deep Learning Through Convolutional Neural Networks," *Int. J. Recent Technol. Eng.*, vol. 8, no. 3, pp. 1463–1465, 2019, doi: 10.35940/ijrte.B3770.098319.
- [18] H. Zuo, J. Tang, and P. Han, "A New Type Method of Adhesive Handwritten Digit Recognition Based on Improved Faster RCNN," in *Proc. IEEE Int. Conf. Signal Image Process.*, 2020, pp. 42–45, doi: 10.1109/ICSIP49896.2020.9339270.
- [19] B. Rahmani and S. Supriyadi, "Early Model of Traffic Sign Reminder Based on Neural Network," *TELKOMNIKA (Telecommun. Comput. Electron. Control)*, vol. 10, no. 4, p. 749, 2012, doi: 10.12928/telkomnika.v10i4.864.