

## **Penerapan *Convolutional Neural Network* untuk Mengklasifikasikan Citra Sampah Organik dan Non Organik**

**Ayuni Tia Sari<sup>1\*</sup>, Jumadi<sup>2</sup>, Eva Nurlatifah<sup>3</sup>**

Teknik Informatika, UIN Sunan Gunung Djati Bandung, Bandung, Indonesia  
 \*e-mail corresponding: 1207050020@student.uinsgd.ac.id

### **Abstract**

*Waste is a major environmental problem in Indonesia that is increasing with population growth. This research aims to apply a Convolutional Neural Network (CNN) based classification model to separate organic and non-organic waste, reduce time, and increase the efficiency of the waste sorting process. By using the CRISP-DM method, there are main components, namely Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, and Deployment. The dataset used consists of 4500 images from Kaggle for training and validation data, and 300 manual images for testing data. The designed model uses VGG-16 architecture with Adam optimizer and learning rate 0.001. The evaluation results show that the model accuracy is 64.33% with a significant error rate in non-organic waste classification. The model is integrated into a Flask-based website application to make it easier for users to upload images and get prediction results. The results of this research are expected to reduce time and increase the efficiency of the waste separation process.*

**Keywords:** *Waste image classification; Waste management; Deep learning*

### **Abstrak**

Sampah menjadi masalah lingkungan utama di Indonesia yang semakin meningkat seiring pertumbuhan populasi. Penelitian ini bertujuan untuk penerapan model klasifikasi berbasis *Convolutional Neural Network* (CNN) untuk memisahkan sampah organik dan non-organik, mengurangi waktu, dan meningkatkan efisiensi proses pemilahan sampah. Dengan menggunakan metode CRISP-DM, terdapat komponen utama yaitu: *Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Deployment*. Dataset yang digunakan terdiri dari 4500 gambar dari Kaggle untuk data training dan validation, serta 300 gambar manual untuk data testing. Model yang dirancang menggunakan arsitektur VGG-16 dengan Adam optimizer dan learning rate 0,001. Hasil evaluasi menunjukkan akurasi model sebesar 64.33% dengan tingkat kesalahan signifikan pada klasifikasi sampah non-organik. Model diintegrasikan ke dalam aplikasi website berbasis *Flask* untuk memudahkan pengguna mengunggah gambar dan mendapatkan hasil prediksi. Hasil penelitian ini diharapkan dapat mengurangi waktu dan meningkatkan efisiensi proses pemisahan sampah.

**Kata kunci:** *Klasifikasi citra sampah; Pengelolaan sampah; Deep learning.*

### **1. Pendahuluan**

Pada dasarnya sampah merupakan sebagai sisa atau benda yang sudah tidak dimanfaatkan setelah digunakan oleh makhluk hidup [1]. Sedangkan menurut UU No. 18 Tahun 2008 tentang Pengelolaan Sampah, sampah adalah sisa dari kegiatan sehari-hari yang dilakukan oleh manusia atau proses alam yang berbentuk padat maupun semi padat yang terdiri dari zat organik dan non-organik yang sudah terbuang [2]. Salah satu masalah yang belum teratasi sepenuhnya di Indonesia yaitu terkait sampah. Volume sampah akan terus meningkat kerana jumlah penduduk yang semakin meningkat [3]. Data tentang produksi sampah pada tahun 2023 yang disediakan oleh Kementerian Lingkungan Hidup dan Kehutanan (KLHK). Menunjukkan bahwa Indonesia menghasilkan limbah sampah sebanyak 41 juta ton/tahun atau setara dengan 113 ribu ton/hari. Komposisi sampah berdasarkan jenis sampah yang dihasilkan dari kegiatan manusia seperti sampah organik sebanyak 62.59%, dengan sampah non-organik sebanyak 30.38% dan jenis sampah lainnya sebanyak 7.03%.

Berdasarkan data tersebut diketahui sampah organik dari sisa makanan merupakan yang terbesar mencapai 39.57% [4]. Pengelolaan sampah yang efektif tidak hanya menjaga kebersihan lingkungan, tetapi juga membantu meminimalkan dampak buruk terhadap kesehatan manusia dan keseimbangan ekosistem. Dalam proses pengelolaan sampah dapat dikelompokkan menjadi dua kategori utama yaitu organik dan non-organik. Sampah organik adalah jenis sampah yang akan mengalami pembusukan, seperti sisa makanan dari dapur serta dedaunan, dan bahan yang dapat diolah menjadi kompos atau mudah terurai di dalam tanah secara alami [5]. Sementara sampah non-organik adalah jenis sampah kering yang bersumber dari kegiatan industri dan teknologi, seperti plastik, logam, kaca, dan lainnya, yang sangat sulit terurai namun dapat didaur ulang menjadi barang yang memiliki manfaat kembali [6].

Pemisahan sampah organik dan non-organik saat ini umumnya dilakukan secara manual yang memerlukan banyak waktu dan sumber daya. Ini seringkali tidak efisien dan dapat menghasilkan kesalahan pemisahan [7]. Walaupun pengelolaan sampah telah diterapkan, masih ada perbedaan antara situasi aktual dan kondisi ideal yang diinginkan. Masalah ini cukup serius, karena sampah organik yang tidak dikelola dengan baik dapat menghasilkan gas metana, sedangkan sampah non-organik seperti plastik berpotensi menimbulkan kerusakan lingkungan dalam jangka panjang. [8]. Klasifikasi sampah organik dan non-organik difokuskan karena kedua jenis sampah ini memberikan dampak besar terhadap lingkungan dan proses daur ulangnya memerlukan pendekatan yang berbeda secara teknis [9]. Dengan demikian, terdapat kebutuhan mendesak untuk menemukan solusi yang lebih efisien dan efektif dalam pemisahan sampah dan pengelolaan sampah.

Dengan kemajuan teknologi dan bidang kecerdasan buatan, terdapat peluang untuk mengotomatisasi proses pemisahan sampah dengan menggunakan *Convolution Neural Network* (CNN) dalam konteks *Deep Learning* dalam klasifikasi gambar [10]. Penelitian sebelumnya menunjukkan CNN telah terbukti efektif dalam klasifikasi gambar, serta menerapkannya dalam mengidentifikasi dan memisahkan gambar sampah organik serta non-organik yang menjadikan terobosan signifikan dalam mengelola sampah yang lebih baik [11]. Penelitian yang dilakukan Kelvin Leonardi Kohsasih dkk, [12]. Membandingkan kinerja algoritma *Convolutional Neural Network* (CNN) dengan algoritma *Multi-Layer Perceptron* (MLP) untuk klasifikasi jenis sampah. Hasilnya menunjukkan bahwa CNN memberikan kinerja dan akurasi yang sangat baik, *recall*, *f1-score*, serta *accuracy* 0,98 yang lebih efektif untuk mengklasifikasi sampah berdasarkan kelas. Penelitian Rian Kurniawan dkk [13]. Fokus utama pada penggunaan model CNN untuk mengklasifikasi jenis sampah yang berpotensi didaur ulang. Model yang dibangun dengan arsitektur *Xception*, pengoptimal Adam, serta learning rate 0,001 mampu mencapai akurasi 87,81%. Menunjukkan sistem klasifikasi limbah sangat efektif.

Dalam penelitian ini bertujuan dapat menganalisis model *Convolution Neural Network* (CNN) dengan optimal untuk melakukan klasifikasi sampah dengan akurasi tinggi. Serta mengidentifikasi performa arsitektur VGG-16 dalam model CNN untuk mengklasifikasi citra sampah organik dan non-organik. Dengan mencapai tujuan ini, penelitian diharapkan dapat memberikan kontribusi signifikan dalam meningkatkan efisiensi proses pemisahan sampah. Selain itu, hasil penelitian diharapkan dapat mendorong praktik daur ulang yang lebih baik dan berkelanjutan, serta memberikan dampak positif bagi lingkungan dan masyarakat secara keseluruhan.

## 2. Tinjauan Pustaka

Penelitian terdahulu telah menunjukkan berbagai upaya dalam mengklasifikasikan citra sampah menggunakan teknologi kecerdasan buatan. Salah satu penelitian yang dilakukan oleh A. Mareta dkk [14], dalam mengembangkan aplikasi android berbasis *Convolutional Neural Network* (CNN) untuk mengidentifikasi limbah infeksius, seperti masker, baterai, dan sisa makanan, dengan akurasi mencapai 94%. Aplikasi ini menjadi solusi inovatif dalam meningkatkan kesadaran dan pengelolaan limbah infeksius di Indonesia.

Selain itu, pada penelitian K. N. Anggraeni [15], menunjukkan bahwa penerapan *Convolutional Neural Network* (CNN) sangat efektif untuk mengklasifikasikan sampah organik, kertas, serta plastik dengan akurasi mencapai 99%. Pendekatan ini memberikan solusi inovatif untuk pengelolaan sampah melalui identifikasi otomatis, mengurangi ketergantungan pada metode manual, dan meningkatkan efisiensi serta partisipasi masyarakat dalam sistem penukaran sampah. Dengan integrasi ke dalam platform berbasis web, sistem ini


memungkinkan klasifikasi sampah secara langsung melalui input gambar, mendorong pengelolaan sampah yang lebih tepat, efektif, dan berkelanjutan.

Pada penelitian I. G. Agung dkk [16], menunjukkan bahwa penggunaan teknologi kecerdasan buatan, khususnya *Convolutional Neural Network* (CNN), dapat secara signifikan meningkatkan efisiensi pengelolaan sampah dengan akurasi klasifikasi mencapai 88%. Dengan menggabungkan model CNN dalam sistem pemilahan otomatis di Tempat Pembuangan Akhir (TPA), proses daur ulang bisa lebih cepat, dan pemilahan sampah menjadi lebih tepat, sehingga mengurangi jumlah sampah plastik yang mencemari lingkungan. Teknologi ini diharapkan menjadi solusi inovatif dalam menghadapi tantangan pengelolaan sampah modern dan mendukung keberlanjutan lingkungan.

Penelitian ini menggunakan arsitektur VGG-16 yang sangat efektif dalam pengenalan citra, dengan fokus pada klasifikasi sampah yang lebih akurat dan relevan. Berbeda dengan penelitian sebelumnya yang sering menggunakan model CNN standar, penelitian ini memanfaatkan keunggulan VGG-16 yang memiliki kemampuan ekstraksi fitur yang lebih baik. Selain itu, dataset yang digunakan untuk pengujian diambil secara manual dari lingkungan sekitar serta dari lingkungan sekolah TK Nurul Islam yang berada di Kecamatan Cibiru Kota Bandung. Pendekatan ini memungkinkan model untuk lebih adaptif terhadap variasi dalam jenis dan kondisi sampah yang ada di lapangan.

### 3. Metodologi

Dalam penelitian ini, pendekatan yang diterapkan adalah metode CRISP-DM (*Cross-Industry Standard Process for Data Mining*) yang diperkenalkan pada tahun 1996 dikembangkan melalui analisis dari berbagai industri, seperti *Daimler Chrysler*, NCR, dan SPSS [17]. Metode ini menyediakan prosedur proses data mining yang menjadi panduan umum untuk menyelesaikan masalah penelitian atau bisnis. CRISP-DM merupakan suatu pendekatan yang dapat digunakan dalam strategi penyelesaian suatu masalah secara umum dan berfungsi sebagai metode standar untuk eksplorasi data atau data mining [18]. Terdapat enam langkah utama pada metode CRISP-DM, seperti yang dapat dilihat pada Gambar 1 berikut.



Gambar 1. Metode CRISP-DM [19]

#### 1) *Business Understanding*

Pada bagian ini, fokus utama pada pemahaman masalah utama yaitu model klasifikasi gambar untuk mendeteksi jenis sampah dalam kategori organik dan non-organik. Bertujuan untuk menerapkan teknologi Deep Learning, terutama pada metode *Convolutional Neural Network* (CNN), dilakukan klasifikasi sampah secara otomatis. Dengan model klasifikasi yang akurat, diharapkan proses pemilahan sampah dapat lebih efisien, serta hemat waktu.

#### 2) *Data Understanding*

Pada bagian ini, bertujuan untuk mengumpulkan serta memahami dataset gambar yang digunakan dalam pelatihan model *Convolutional Neural Network* (CNN) untuk mengklasifikasi citra sampah. Dataset awal yang diambil dari kaggle sebanyak 18463 gambar. Namun, untuk memastikan kualitas dataset serta mengoptimalkan proses pelatihan dan validasi, jumlah dataset dikurangi menjadi 4500 gambar. Pengurangan dataset ini dilakukan untuk menghindari *overfitting* dan memudahkan pengelolaan data tanpa menurunkan performa model secara signifikan. Pada Tabel 1 menunjukkan gambar dataset yang digunakan dari kaggle untuk data

training dan validation sebanyak 4500 gambar, sedangkan pada Tabel 2 menunjukkan gambar untuk data testing yang dikumpulkan secara manual sebanyak 300 gambar. Terdapat sembilan kelas jenis sampah yaitu dalam kategori organik terdapat tiga kelas, yaitu *biological*, *paper*, *cardboard*, sedangkan dalam kategori non-organik terdapat enam kelas, yaitu *plastic*, *metal*, *glass*, *clothes*, *shoes*, *trash*.

Tabel 1. Jumlah Dataset Kaggle

Gambar									
Kelas	Biological	Paper	Cardboard	Plastic	Metal	Glass	Clothes	Shoes	Trash
Jumlah	500	500	500	500	500	500	500	500	500

Tabel 2. Jumlah Dataset Manual

Gambar									
Kelas	Biological	Paper	Cardboard	Plastic	Metal	Glass	Clothes	Shoes	Trash
Jumlah	129	7	14	32	14	6	6	6	86

### 3) Data Preparation

Pada tahap ini, terdapat dua proses penting yaitu preprocessing dan augmentasi. Tahap *preprocessing* bertujuan untuk mempersiapkan data sebelum digunakan dalam model. Gambar dinormalisasi dengan membagi nilai piksel dari rentang [0,255], menjadi [0,1] yang lebih optimal untuk model deep learning. Selain itu, semua ukuran gambar diubah menjadi 128 x 128 piksel, menyesuaikan ukuran gambar untuk model yang akan dilatih. Pada augmentasi data dilakukan untuk meningkatkan variasi data dengan teknik seperti *scaling*, *rotation*, *shifting*, *zooming*, dan *horizontal flipping*, bertujuan untuk memberikan model lebih banyak data untuk dilatih.

Kemudian, pada tabel 3 terdapat tiga bagian utama yaitu data training, validation, dan testing. Data training dan validation diperoleh dari dataset kaggle, sementara data testing diperoleh dari gambar hasil foto manual. Dataset dari kaggle untuk data training 75% dan 19% untuk data validation, serta dataset manual sebesar 6%.

Tabel 3. Pembagian Data

Data Kategori	Jumlah	Persentase
<i>Training</i>	3600	<b>75%</b>
<i>Validation</i>	900	<b>19%</b>
<i>Testing</i>	300	<b>6%</b>

### 4) Modeling

Model yang digunakan adalah CNN yang dibangun menggunakan library TensorFlow dari bahasa pemrograman python, dengan arsitektur VGG-16. VGG-16 merupakan model yang terkenal karena kedalamannya yang mencapai 16 lapisan, yang memungkinkan ekstraksi fitur yang lebih kompleks dan mendetail dari citra. Struktur layer CNN disusun dengan tiga blok konvolusi pada *block 1* 32 filter, *block 2* 62 filter, dan *block 3* 128 filter yang diikuti oleh lapisan batch normalization, max pooling, dan dropout untuk regularisasi. Hyperparameter model termasuk learning rate sebesar 0,001, fungsi aktivasi menggunakan ReLU, dan menggunakan Adam optimizer. Dengan model yang dilatih selama 50 epoch. Setelah model dibangun, langsung dilatih menggunakan dataset yang sudah disiapkan, yang memungkinkan model untuk mempelajari pola yang ada pada dataset dan dapat membedakan gambar berdasarkan label, seperti mengenali karakteristik sampah plastik, biological, dan jenis lainnya.

### 5) Evaluation

Tahap evaluasi dilakukan dengan memanfaatkan data uji guna menilai performa model klasifikasi. Menunjukkan akurasi prediksi model berdasarkan kategori utama yaitu organik dan non-organik. Evaluasi yang dilakukan dengan menggunakan metrik seperti *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-score*. *Confusion matrix* digunakan sebagai alat untuk analisis hasil prediksi model dengan membandingkan prediksi model terhadap label sebenarnya, sehingga memberikan gambaran menyeluruh terkait performa model. Berdasarkan *confusion matrix*, nilai (TP) true positive 96, (TN) true negative 97, (FP) false positive 54, dan (FN) false negative 53. Berikut rumus perhitungan matrix evaluasi. *Accuracy* untuk mengukur persentase prediksi model yang benar terhadap keseluruhan data.

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

$$Accuracy = \frac{96 + 97}{96 + 97 + 54 + 53} = \frac{193}{300} = 0,6433 \text{ (64,33\%)}$$

*Precision* digunakan untuk mengetahui seberapa relevan prediksi model. Persentase data untuk diprediksi sebagai positif serta benar-benar positif dari total prediksi positif.

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

$$Precision_{Organik} = \frac{96}{96 + 54} = \frac{96}{150} = 0,64$$

$$Precision_{Non-organik} = \frac{97}{97 + 53} = \frac{97}{150} = 0,6467$$

*Recall* menunjukkan kemampuan deteksi model terhadap data positif. Persentase data dianggap positif jika berhasil diklasifikasikan dengan tepat dari keseluruhan data positif yang sebenarnya.

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

$$Recall_{Organik} = \frac{96}{96 + 54} = \frac{96}{150} = 0,64$$

$$Recall_{Non-organik} = \frac{97}{97 + 53} = \frac{97}{150} = 0,6467$$

*F1-Score* merupakan rata-rata gabungan antara *precision* dan *recall*.

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

$$F1 - Score_{Organik} = 2 \times \frac{0,64 \times 0,64}{0,64 + 0,64} = 2 \times \frac{0,4096}{1,28} = 0,64$$

$$F1 - Score_{Non-organik} = 2 \times \frac{0,6467 \times 0,6467}{0,6467 + 0,6467} = 2 \times \frac{0,4182}{1,2934} = 0,6467$$

Keterangan:

- True Positive* (TP): Sejumlah data positif jika berhasil diklasifikasi dengan benar sebagai positif.
- True Negative* (TN): Sejumlah data negatif jika berhasil diklasifikasi dengan benar sebagai negatif.
- False Positive* (FP): Sejumlah data negatif jika salah diklasifikasi sebagai positif.
- False Negative* (FN): Sejumlah data positif jika salah diklasifikasi sebagai negatif.

#### 6) Deployment

Pada bagian terakhir ini, mengintegrasikan model yang sudah dilatih ke dalam aplikasi website menggunakan Flask. Dengan ini, penggunaan dapat mengunggah gambar sampah serta mendapatkan hasil klasifikasi model dengan langsung melalui antarmuka web.


## 4. Hasil dan Pembahasan

### 4.1 Hasil


Jumlah gambar untuk penelitian yang digunakan dari dataset kaggle sebanyak 4500 gambar. Sedangkan jumlah gambar yang dikumpulkan secara manual sebanyak 300 gambar, yang berasal dari sisa makanan anak-anak TK Nurul Islam, serta dari lingkungan sekitar. Kemudian terdapat beberapa bagian data yaitu pada data training memiliki sebanyak 3600 gambar, data validation sebanyak 900 gambar, sedangkan data testing sejumlah 300 gambar. Sejumlah gambar terbagi menjadi beberapa jenis yang terdiri dari *biological, paper, cardboard, plastic, metal, glass, clothes, shoes, dan trash*. Model dilatih menggunakan dataset kaggle terdiri dari data *training* dan *validation*. Kemudian data yang dilatih menggunakan 50 epoch dengan visualisasi hasil berupa grafik *accuracy* dan *loss*.

Pada Gambar 2 grafik akurasi *training and validation*, akurasi *training* meningkat secara signifikan di awal epochs, kemudian mulai stabil di sekitar epoch 20 hingga akhir pelatihan. Menunjukkan model mempelajari data *training* dengan baik. Pada *validation accuracy* juga meningkat di awal, tetapi peningkatannya tidak selancar *training accuracy*. Terdapat *fluktuasi* yang menunjukkan adanya *overfitting* atau *underfitting*. *Overfitting* terjadi pada suatu model yang terlalu baik dalam mempelajari data pelatihan menyebabkan kinerja model kurang optimal pada data baru. *Underfitting* terjadi saat model tidak cukup mempelajari data latih sehingga kinerjanya buruk pada data *training* dan *validation*. Dalam hal ini, terlihat kecenderungan *overfitting* ringan karena *validation accuracy* sedikit lebih rendah dari *training accuracy* di akhir pelatihan.

Pada Gambar 3 grafik *training* dan *validation loss*, nilai *training loss* menurun secara drastis di awal epochs, kemudian menurun secara perlahan hingga mendekati nilai konstan di akhir pelatihan. Menunjukkan model semakin baik dalam memprediksi data *training*. Nilai pada *validation loss* juga menurun di awal, tetapi penurunannya tidak selancar *training loss*. Terdapat *fluktuasi* yang serupa dengan grafik *accuracy*, terlihat kecenderungan *overfitting* ringan, karena *validation loss* sedikit lebih tinggi dari *training loss* di akhir pelatihan, tetapi tetap rendah.



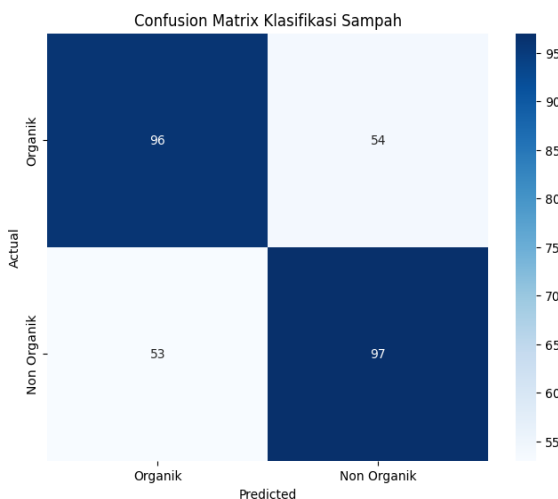
Gambar 2. Grafik Training dan Validation Accuracy



Gambar 3. Grafik Training dan Validation Loss

Fase *testing*, model dilatih menggunakan dataset manual sebanyak 300 gambar. Hasil data testing yang didapat berdasarkan akurasi kategori utama sebesar 64.33%. Sebanyak 193 gambar berhasil diklasifikasikan dengan benar, sedangkan 107 gambar salah diprediksi. Tingkat kesalahan yang cukup signifikan, terutama pada kategori sampah non-organik yang disebabkan oleh berbagai hal. Salahnya adalah keterbatasan variasi dalam dataset training, yang membuat model kurang mengenali berbagai bentuk sampah. Selain itu, kemiripan fitur antara sampah organik dan non-organik, seperti pada warna dan tekstur. Ketidakseimbangan jumlah data antar kategori pun berpotensi memengaruhi kemampuan model untuk membedakan kategori dengan akurat.

Gambar 4 *confusion matrix* menunjukkan hasil klasifikasi sampah menjadi organik dan non-organik. Dari 150 sampel sampah organik, model mengklasifikasikan 96 sampel dengan benar sebagai organik (*true positive*) dan salah mengklasifikasikan 54 sampel sebagai non-organik (*false negative*). Sementara dari 150 sampel sampah non-organik, model mengklasifikasikan 97 sampel dengan benar sebagai non-organik (*true negative*) dan salah mengklasifikasikan 53 sampel sebagai organik (*false positive*). Dengan warna yang lebih gelap pada sel matriks menunjukkan jumlah yang lebih tinggi.



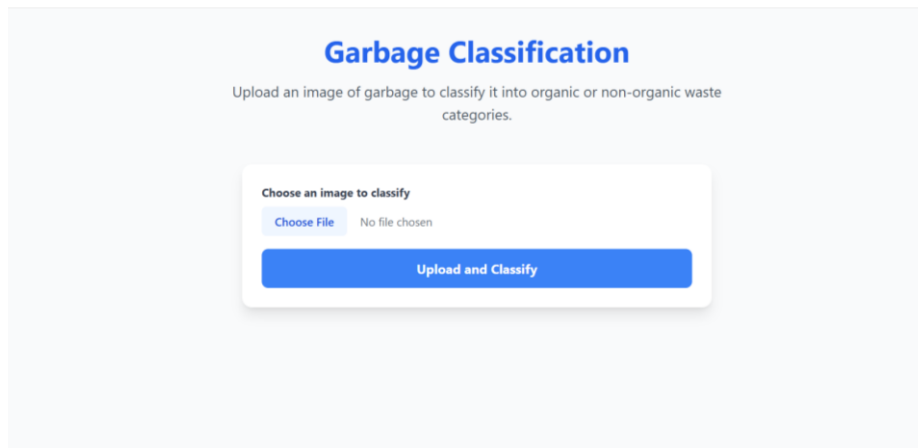
Gambar 4. *Confusion Matrix*

Tabel 4 merupakan hasil dari perhitungan evaluation, di mana evaluation model didasarkan pada perhitungan accuracy, precision, recall, dan f1-score. Nilai yang terdapat pada tabel diperoleh melalui analisis terhadap performa model klasifikasi sampah. Model menunjukkan performa yang seimbang untuk kedua kelas, dengan nilai metrik sekitar 0.64. Akurasi keseluruhan model 64.33%. Menunjukkan bahwa model memiliki performa yang seimbang antara deteksi kategori organik dan non-organik, namun akurasi secara keseluruhan masih dapat ditingkatkan.

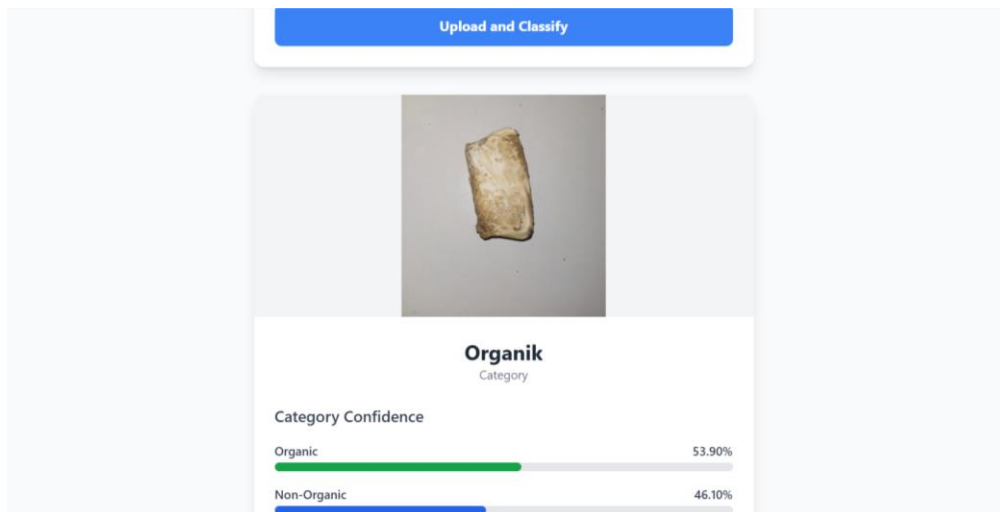
Tabel 4. *Classification report*

Metrik	Organik	Non-organik	Rata-rata (macro avg)	Rata-rata (weighted avg)	Support
<i>Precision</i>	0.64	0.64	0.64	0.64	150
<i>Recall</i>	0.65	0.64	0.64	0.64	150
<i>F1-score</i>	0.64	0.64	0.64	0.64	150
<i>Accuracy</i>			64,33%		300

Kemudian model yang telah dilatih pada *Python* akan dilakukan tahap *deploy* ke dalam aplikasi website menggunakan flask. Dengan ini, penggunaan dapat mengunggah gambar sampah sehingga dapat menampilkan hasil prediksi dari gambar sampah tersebut. Pada Gambar 5, menunjukkan antarmuka sistem yang digunakan untuk mengunggah file. Tampilan ini dirancang untuk memudahkan pengguna dalam mengunggah file dari perangkat mereka ke sistem.



Gambar 5. Halaman untuk mengunggah citra sampah



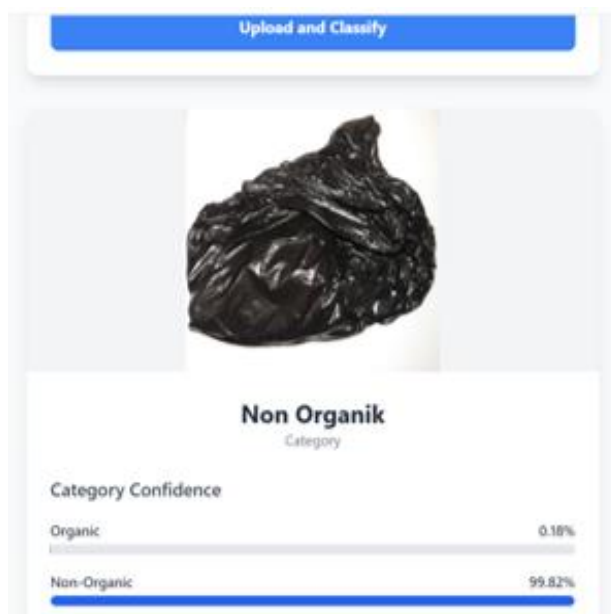
Gambar 6. Citra sampah dengan prediksi organik

Gambar 6 menunjukkan hasil prediksi untuk sampah organik, dimana sistem berhasil mengenali gambar tempe yang sudah busuk tersebut sebagai sampah organik. Pada *category confidence* yang menunjukkan tingkat kepercayaan sistem terhadap prediksinya terdapat dua nilai, organik 53.90% dan non-organik 46.10%. Dengan demikian meskipun sistem dapat memprediksi sampah dengan benar sebagai sampah organik, namun tingkat *confidence* relatif rendah.

Pada Gambar 7 menunjukkan hasil prediksi untuk sampah non-organik yaitu plastik hitam. Hasil prediksi tersebut mengenali sebagai sampah non-organik. Dengan nilai *category*



*confidence* pada prediksi organik 0.18% dan non-organik 99.82%. Sistem mengklasifikasikan sampah tersebut sebagai non-organik dengan tingkat kepercayaan yang sangat tinggi.



Gambar 7. Citra Sampah Dengan Prediksi Non-Organik

#### 4.2 Pembahasan

Hasil pengujian ini menunjukkan bahwa model CNN yang dibangun dengan akurasi yang cukup baik masih terdapat ruang untuk perbaikan. Akurasi 64.33% menunjukkan potensi dalam menyelesaikan masalah pemisahan sampah yang telah diidentifikasi sebelumnya, dimana pemisahan sampah secara manual sering kali memerlukan banyak waktu dan sumber daya, serta dapat menghasilkan kesalahan pemisahan. Dengan penerapan model CNN, diharapkan proses pemisahan sampah dapat dilakukan secara otomatis dan lebih efisien, sehingga mengurangi beban kerja manusia dan meningkatkan akurasi dalam klasifikasi jenis sampah.

Relevansi penelitian ini terhadap penelitian terdahulu sangat signifikan. Sebagai contoh, penelitian [20] membuktikan bahwa CNN mampu menghasilkan akurasi tinggi dalam mengklasifikasikan jenis sampah, dengan nilai *recall* dan *F1-score* yang tinggi mencapai 87.81%. Dalam penelitian ini meskipun menunjukkan akurasi yang lebih rendah, yaitu 64.33%, hal ini dapat dipahami sebagai tantangan yang dihadapi dalam mengklasifikasikan sampah non-organik yang memiliki kemiripan fitur dengan sampah organik.

Posisi temuan dalam penelitian ini menunjukkan bahwa meskipun akurasi yang dicapai belum sebanding dengan penelitian sebelumnya, penelitian ini berperan signifikan dalam mengembangkan sistem klasifikasi yang lebih adaptif dan realistis dengan memanfaatkan dataset yang diperoleh dari lingkungan sekitar. Dengan demikian, penelitian ini berkontribusi pada pengintegrasian temuan-temuan sejenis yang telah ada, serta memberikan wawasan baru tentang tantangan yang dihadapi dalam klasifikasi citra sampah, terutama dalam konteks pengelolaan sampah yang lebih efektif dan berkesinambungan.

#### 5. Simpulan

Penelitian ini berhasil merancang dan menguji model *Convolutional Neural Network* (CNN) untuk mengklasifikasikan citra sampah organik dan non-organik. Model mencapai akurasi 64.33% berdasarkan dataset manual sebanyak 300 gambar. Sebanyak 193 gambar berhasil diklasifikasikan dengan benar, sementara 107 gambar salah prediksi. Model menunjukkan performa yang seimbang untuk kedua kategori utama dengan dengan nilai *precision*, *recall*, dan *f1-score* sekitar 0,64. Meskipun hasil menunjukkan potensi, tingkat kesalahan yang signifikan, terutama pada kategori non-organik, mengindikasikan perlunya perbaikan lebih lanjut. Faktor yang memengaruhi kinerja meliputi keterbatasan variasi dataset, kemiripan fitur antar kategori dan ketidakseimbangan jumlah data antar kelas. Model ini telah

diimplementasikan dalam aplikasi web berbasis flask yang memungkinkan prediksi otomatis pada citra sampah. Untuk meningkatkan performa model disarankan agar dataset diperluas dengan menambahkan variasi gambar dari berbagai lingkungan dan kondisi pencahayaan, serta menggunakan augmentasi yang lebih beragam. Implementasi ini dapat diperluas pada perangkat *Internet of Things* (IoT), seperti tempat sampah yang dilengkapi dengan kamera, untuk mendukung pengelolaan secara otomatis.

#### Daftar Referensi

- [1] L.G.M.L Susanti and N. N. J. Arsawati, "Alternatif Strategi Pengelolaan Sampah Berbasis Pemberdayaan Masyarakat Melalui Bank Sampah Di Desa Tunjuk, Tabanan," *Kaibon Abhinaya J. Pengabd. Masy.*, vol. 3, no. 2, pp. 105–110, 2021, doi: 10.30656/ka.v3i2.3111.
- [2] D. J. K. Negara, "Pengelolaan sampah di Indonesia 2022." [Online]. Available: <https://www.antaraneews.com/infografik/3331290/pengelolaan-sampah-di-indonesia-2022>
- [3] L. Faizal, Y. Yuyun, and H. Hazriani, "Identifikasi Sampah Plastik Menggunakan Algoritma Deep Learning," *J. Ilm. Sist. Inf. dan Tek. Inform.*, vol. 6, no. 2, pp. 162–171, 2023, doi: 10.57093/jisti.v6i2.176.
- [4] SIPSN, "Sistem Informasi Pengelolaan Sampah Nasional," 2024. [Online]. Available: <https://sipsn.menlhk.go.id/sipsn/public/data/timbangan>
- [5] O. D. S. Sunanto and P. H. Utomo, "Implementasi Deep Learning Dengan Convolutional Neural Network Untuk Klasifikasi Gambar Sampah Organik Dan Anorganik," *Pattimura Proceeding Conf. Sci. Technol.*, vol. 1, no. 2, pp. 335–340, 2022, [Online]. Available: <https://jurnal.unej.ac.id/index.php/prosiding/article/view/33527>
- [6] A. A. Firdaus, A. Yudhana, and I. Riadi, "Penerapan Model Arsitektur VGG16 Untuk Klasifikasi Jenis Sampah," *Decod. J. Pendidik. Teknol. Inf.*, vol. 3, no. 2, pp. 236–245, 2023, [Online]. Available: <http://journal.umkendari.ac.id/index.php/decode>
- [7] A. N. Sihananto, M. M. Al Haromainy, and A. P. Sari, "Pemilahan Jenis Sampah Menggunakan Algoritma CNN," *Scan J. Teknol. Inf. dan Komun.*, vol. 17, no. 3, pp. 23–27, 2022.
- [8] R. Adelia, N. Khairunisa, and R. Zulfiqri, "Implementasi Convolutional Neural Network (Cnn) Dalam Mendeteksi Sampah Organik, Plastik, Dan Kertas," *JUTIM (Jurnal Tek. Inform. Musirawas)*, vol. 9, no. 1, pp. 29–37, 2024, doi: 10.32767/jutim.v9i1.2233.
- [9] A. R. Fahcuroji, Madona Yunita Wijaya, and Irma Fauziah, "Implementasi Algoritma Cnn Mobilenet Untuk Klasifikasi Gambar Sampah Di Bank Sampah," *PROSISKO J. Pengemb. Ris. dan Obs. Sist. Komput.*, vol. 11, no. 1, pp. 45–51, 2024, doi: 10.30656/prosisko.v11i1.8101.
- [10] A. P. P Prasetyo, M. Irfansyah, K. Exaudi, T. Wanda Septian, and Rendyansyah, "Sistem Pemilahan Sampah Organik Berbasis Raspberry Pi Menggunakan Klasifikasi CNN Raspberry Pi Based Organic Waste Sorting System Using CNN Classification," *J. Sisfotenika*, vol. 13, no. 1, pp. 76–90, 2023, [Online]. Available: <http://sisfotenika.stmikpontianak.ac.id/index.php/ST>
- [11] V. R. Ho, S. Devella, and D. Alamsyah, "Klasifikasi Media Pembuangan Sampah Menggunakan Metode Resnet101-V2," *MDP Student Conf.*, vol. 2, no. 1, pp. 151–157, 2023, doi: 10.35957/mdp-sc.v2i1.4338.
- [12] K. L. Kohsasih, M. Dipo, A. Rizky, T. Fahriyani, V. Wijaya, and R. Rosnelly, "Analisis Perbandingan Algoritma Convolutional Neural Network Dan Algoritma Multi-Layer Perceptron Neural Dalam Klasifikasi Citra Sampah," *J. Technol. Informatics dan Comput. Syst.*, vol. 10, no. 2, pp. 22–28, 2021, [Online]. Available: <http://ejournal.stmik-time.ac.id>
- [13] R. Kurniawan, P. B. Wintoro, Y. Mulyani, and M. Komarudin, "Implementasi Arsitektur Xception Pada Model Machine Learning Klasifikasi Sampah Anorganik," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, pp. 233–236, 2023, doi: 10.23960/jitet.v11i2.3034.
- [14] A. Mareta, B. E. Adiana, O. Wardhani, I. Alfath, and N. Fathony, "Implementasi Model Convolutional Neural Network dalam Aplikasi Android untuk Identifikasi Limbah Infeksius," vol. 8, no. 2, pp. 113–124, 2024.
- [15] K. N. Anggraeni, "Penerapan Convolutional Neural Network (CNN) untuk Klasifikasi Sampah dan Optimalisasi Sistem Penukaran Sampah," *JIMU J. Ilm. Multi Disiplin*, vol. 02, no. 03, pp. 3031–9498, 2024.
- [16] I. G. Agung, G. Arya, I. N. Artawan, and P. Herdy, "Klasifikasi Sampah Berbasis

- Convolutional Neural Networks ( CNN ) untuk Peningkatan Efisiensi Pengelolaan Sampah,” vol. 17, pp. 136–147, 1979.
- [17] A. K. Neighbor, L. Purnama, and T. Wahyudi, “Analisa Sentimen Tentang Piala Dunia u-20 Indonesia Menggunakan,” vol. 6, no. 2, pp. 217–222, 2024.
- [18] Z. Rahman Hakim and S. Sugiyono, “Analisa Sentimen Terhadap Kereta Cepat Jakarta – Bandung Menggunakan Algoritma Naïve Bayes Dan K-Nearest Neighbor,” *J. Sains dan Teknol.*, vol. 5, no. 3, pp. 939–945, 2024, doi: 10.55338/saintek.v5i3.1423.
- [19] V. E. Smart, “Apa metodologi CRISP-DM? 2020” [Online]. Available: <https://www.sv-europe.com/crisp-dm-methodology/>
- [20] Z. I. Nugraha, K. Saputra, A. Setiawan, R. Maharani, and F. Zaharani, “Implementasi Algoritma Cnn Dalam Pengembangan Website Untuk Klasifikasi Sampah Organik, Dan Non-Organik,” *J. Manaj. Inform. dan Sist. Inf.*, vol. 8, no. 1, pp. 90–101, 2025.