

**IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK
KLASIFIKASI SAMPAH ORGANIK DAN NON-ORGANIK BERBASIS CITRA
DIGITAL**

Dimas Bani Agung Frandika¹, Safik fahreza², Faizal Adi Saputra³, Tri Anggoro⁴

^{1,2,3,4}Universitas Nahdlatul Ulama Al Ghazali Cilacap

Email: dimasfrandika87@gmail.com¹, rezhazha314@gmail.com²,
vaizaladisaputra@gmail.com³, trianggoro1103@unugha.id⁴

Abstrak: Permasalahan penumpukan sampah menjadi isu lingkungan yang terus meningkat seiring pertumbuhan penduduk dan pola konsumsi masyarakat. Salah satu kendala utama dalam pengelolaan sampah adalah proses pemilahan sampah organik dan non-organik yang masih dilakukan secara manual sehingga kurang efisien dan rentan terhadap kesalahan manusia. Penelitian ini bertujuan untuk menerapkan metode Convolutional Neural Network (CNN) dalam proses klasifikasi citra sampah secara otomatis ke dalam dua kategori, yaitu organik dan non-organik. Dataset yang digunakan merupakan dataset sekunder dari Kaggle yang terdiri atas 22.564 citra digital sampah. Model dibangun menggunakan bahasa pemrograman Python dengan pustaka TensorFlow/Keras. Hasil penelitian menunjukkan bahwa model CNN mampu mencapai akurasi pengujian di atas 90%, dengan nilai True Positive sebesar 94% dan True Negative sebesar 93%. Model juga berhasil diintegrasikan ke dalam antarmuka grafis (GUI) berbasis desktop yang mampu melakukan deteksi real-time menggunakan webcam. Penelitian ini menunjukkan bahwa metode CNN memiliki potensi yang baik untuk diterapkan pada sistem pemilahan sampah otomatis berbasis kecerdasan buatan.

Kata Kunci: Convolutional Neural Network (CNN), Klasifikasi Sampah, Deep Learning, Citra Digital, Real-Time Detection.

***Abstract:** The problem of waste accumulation is an environmental issue that continues to grow along with population growth and consumption patterns. One of the main obstacles in waste management is the manual separation of organic and non-organic waste, which is inefficient and prone to human error. This study aims to apply the Convolutional Neural Network (CNN) method to automatically classify waste images into two categories: organic and non-organic. The dataset used is a secondary dataset from Kaggle, consisting of 22,564 digital waste images. The model was built using the Python programming language with the TensorFlow/Keras library. The results showed that the CNN model achieved a testing accuracy above 90%, with a True Positive rate of 94% and a True Negative rate of 93%. The model was also successfully integrated into a desktop-based graphical user interface (GUI) capable of real-time detection using a webcam. This research demonstrates that the CNN method has good potential for application in an artificial intelligence-based automatic waste sorting system.*

***Keywords:** Convolutional Neural Network (CNN), Garbage Classification, Deep Learning, Digital Image, Real-Time Detection.*

PENDAHULUAN

Sampah merupakan salah satu permasalahan utama yang mendesak di kota-kota besar maupun daerah berkembang. Berdasarkan data dari Kementerian Lingkungan Hidup dan Kehutanan (KLHK), volume timbulan sampah nasional terus mengalami peningkatan signifikan setiap tahunnya, di mana persentase terbesar didominasi oleh sisa makanan domestik dan limbah kemasan plastik yakni sekitar 41% (Kementerian Lingkungan Hidup dan Kehutanan, 2025). Berdasarkan data Sistem Informasi Pengelolaan Sampah Nasional (SIPSN), volume timbulan limbah domestik di Indonesia terus melonjak drastis mencapai 24,94 juta ton timbulan sampah menurut (Sistem Informasi Pengelolaan Sampah Nasional, 2021), tanpa diimbangi oleh infrastruktur pemilahan yang memadai di tingkat hulu. Pola pengelolaan yang tidak integratif ini mendesak diterapkannya sistem kategorisasi sampah organik dan non-organik berbasis komputasi cerdas guna mereduksi akumulasi residu di Tempat Pemrosesan Akhir (Oktayessofa et al., 2024; Sahibu & Taufik, 2024).

Pemilahan sampah berdasarkan karakteristik organik dan non-organik pada dasarnya sangat penting karena berpengaruh langsung terhadap efisiensi proses daur ulang dan manajemen pengolahan limbah lanjutan. Namun, dalam praktiknya masyarakat masih sering mencampur sampah organik dan non-organik. Fenomena tersebut menjadi salah satu kendala utama dalam proses pengelolaan limbah lanjutan karena dapat menurunkan efektivitas daur ulang dan pengolahan sampah. Penelitian sebelumnya juga menunjukkan bahwa tingkat pengetahuan masyarakat mengenai pemilahan sampah yang benar masih tergolong rendah serta belum dilakukan secara konsisten pada tingkat domestik (Aulia et al., 2024), studi yang membuktikan bahwa tingkat pengetahuan dasar pemilahan yang benar serta konsistensi pelaksanaan pemilahan di tingkat domestik memang masih sangat terbatas (Artikel et al., 2022).

Perkembangan teknologi Artificial Intelligence (AI), khususnya pada bidang Deep Learning, memungkinkan komputer untuk mengenali, menginterpretasikan, dan mengklasifikasikan objek melalui citra digital secara otomatis. Deep Learning merupakan cabang kecerdasan buatan yang berkembang pesat dan banyak diterapkan pada bidang computer vision (Sahibu & Taufik, 2024). Salah satu metode yang banyak digunakan dalam bidang computer vision adalah Convolutional Neural Network (CNN) (Oktayessofa et al., 2024), CNN merupakan arsitektur deep learning yang mampu mengekstraksi fitur visual citra secara otomatis untuk kebutuhan klasifikasi dan deteksi objek berdasarkan pola spasial yang terdapat pada data gambar. (Aulia et al., 2024). Berbeda dengan algoritma *Machine Learning*

konvensional seperti *Multi-Layer Perceptron* (MLP) atau *Support Vector Machine* (SVM) yang membutuhkan ekstraksi fitur manual (*hand-crafted features*) yang rumit, CNN mampu mengekstraksi fitur spasial citra secara otomatis melalui proses convolution (Mustafi et al., 2022). Kelebihan ekstraksi fitur adaptif ini membuat CNN jauh lebih unggul dalam mengenali variasi bentuk geometri objek tidak beraturan dibandingkan algoritma konvensional (Bahagia & Akbar, 2024; Mustafi et al., 2022). Oleh karena itu, penelitian ini mengangkat implementasi model CNN untuk mendeteksi jenis sampah secara otomatis dan *real-time* menggunakan kamera (*webcam*) berbasis Python untuk menangkap objek secara langsung di lapangan (Sari et al., n.d.).

Rumusan Masalah

1. Bagaimana arsitektur dan cara kerja model CNN dalam mengekstraksi fitur citra untuk klasifikasi sampah?
2. Bagaimana tingkat akurasi dan performa empiris model CNN dalam mengklasifikasikan sampah organik dan non-organik secara tepat?
3. Bagaimana bentuk implementasi model berbasis Python ke dalam antarmuka grafis (GUI) desktop untuk pengujian secara *real-time*?

Tujuan Penelitian

1. Merancang dan mengonstruksikan arsitektur model CNN yang optimal untuk klasifikasi sampah biner.
2. Menguji dan mengevaluasi tingkat akurasi serta parameter performa empiris model lewat pengujian data uji.
3. Mewujudkan solusi teknologi pemilahan sampah otomatis yang aplikatif melalui antarmuka visual desktop terintegrasi kamera.

Manfaat Penelitian

1. Memberikan kontribusi praktis dalam pengelolaan sampah modern di tingkat hulu secara efektif.
2. Mendukung realisasi konsep kota cerdas (*smart city*) dalam aspek tata kelola lingkungan berbasis teknologi.
3. Menjadi rujukan ilmiah dan referensi pembelajaran dalam pengembangan aplikasi AI, *deep learning*, dan *computer vision*.

LANDASAN TEORI

1) Convolutional Neural Network (CNN)

Sebagai perkembangan lebih lanjut dalam kecerdasan buatan, *Convolutional Neural Network* (CNN) merupakan kelompok model *deep learning* yang secara spesifik dirancang untuk menangkap pola-pola lokal pada suatu data spasial (Naufal et al., 2021). Arsitektur ini termasuk ke dalam jenis arsitek model yang melakukan *supervised learning*. Secara mendasar, struktur internal CNN tetap memanfaatkan prinsip dasar jaringan saraf buatan, di mana ia tersusun atas kumpulan neuron yang memiliki parameter *weight*, bias, serta *activation function* untuk memproses data masukan. Keunggulan utama dari metodologi ini terletak pada efisiensi kerja arsitektur dan lapisan-lapisan penyusunnya yang mampu mengurai karakteristik objek secara mendalam. Algoritma ini pun kini telah banyak diintegrasikan ke dalam berbagai aplikasi sistem di dunia nyata guna memecahkan tantangan klasifikasi maupun deteksi objek secara akurat dan otomatis.

Dalam implementasinya, arsitektur CNN tersusun atas beberapa komponen kunci:

1. Convolution Layer: Berfungsi mengekstraksi fitur visual dari gambar lewat perkalian matriks kernel filter (Oktayessofa et al., 2024). untuk mempercepat waktu komputasi pelatihan model. Secara matematis, proses convolution pada CNN dilakukan melalui operasi perkalian antara matriks citra input dengan kernel atau filter untuk menghasilkan feature map yang digunakan dalam proses ekstraksi fitur citra. Operasi convolution dapat dinyatakan sebagai berikut (Oktayessofa et al., 2024): $(I * K)(x, y) = \sum_m \sum_n I(x - m, y - n)K(m, n)$.
2. Pooling Layer: Berfungsi mereduksi dimensi spasial data untuk menghemat daya komputasi dengan tetap mempertahankan informasi esensial (Huri et al., 2026).
3. Dense Layer: Bertindak sebagai lapisan koneksi penuh (*fully connected*) untuk melakukan keputusan klasifikasi akhir (Huri et al., 2026).

Melalui rangkaian lapisan convolution, pooling, dan dense layer, CNN mampu mengekstraksi fitur visual secara bertahap dari citra masukan. Proses tersebut memungkinkan model mengenali pola bentuk, tekstur, dan karakteristik objek secara otomatis. Kemampuan ini menjadikan CNN efektif untuk berbagai tugas klasifikasi citra karena mampu mempertahankan informasi spasial penting serta mengurangi kompleksitas data selama proses pembelajaran model (Oktayessofa et al., 2024; Sahibu & Taufik, 2024). Oleh karena itu,

integrasi CNN digunakan sebagai metode utama untuk melakukan klasifikasi citra sampah organik dan non-organik secara otomatis berdasarkan karakteristik visual objek.

2) Rumus Convolution

Operasi konvolusi merupakan proses utama dalam CNN yang bertujuan mengekstraksi fitur visual dari citra masukan. Pada proses ini, kernel atau filter digeser secara sistematis pada setiap bagian citra untuk menghasilkan feature map yang merepresentasikan karakteristik penting objek seperti tepi, tekstur, dan pola spasial. Semakin dalam lapisan konvolusi yang digunakan, semakin kompleks fitur yang dapat dipelajari oleh model (Sahibu & Taufik, 2024).

$$S(i,j)=\sum_m\sum_n I(i-m,j-n)K(m,n)$$

Keterangan

1. $S(i,j)$ = hasil feature map pada posisi (i,j)
2. I = citra input
3. K = kernel atau filter konvolusi
4. m,n = indeks elemen kernel

3) Karakteristik Sampah Organik dan Non-Organik

Klasifikasi sampah menjadi kategori organik dan non-organik merupakan tahapan penting dalam proses pengelolaan limbah. Pemilahan yang tepat dapat meningkatkan efektivitas daur ulang, mengurangi volume sampah yang masuk ke Tempat Pemrosesan Akhir (TPA), serta mendukung penerapan pengelolaan lingkungan yang berkelanjutan.

1. Sampah organik merupakan material yang bersifat *biodegradable* atau dapat terurai secara alami melalui aktivitas mikroorganisme. Jenis sampah ini umumnya berasal dari makhluk hidup, seperti sisa makanan, sayuran, daun, dan material organik lainnya. Apabila dipisahkan dan dikelola dengan baik, sampah organik dapat dimanfaatkan kembali melalui proses dekomposisi biologis menjadi kompos yang bermanfaat bagi lingkungan (Lingkungan & Ahmad, 2022).
2. Sampah Non-Organik merupakan material sintetis non-hayati yang resisten terhadap proses pembusukan alami, seperti plastik dan kaleng. Karakteristiknya yang persisten membutuhkan intervensi teknologi mutakhir guna mempercepat pemilahannya demi mendukung pemulihan material (*material recovery*) dalam sirkular ekonomi (Sahibu & Taufik, 2024).

Pemilahan sampah organik dan non-organik secara manual masih menghadapi berbagai kendala, seperti rendahnya konsistensi masyarakat dalam melakukan pemisahan sampah serta keterbatasan dalam mengidentifikasi jenis material secara cepat dan akurat. Kondisi tersebut dapat mengurangi efektivitas proses pengelolaan limbah dan daur ulang pada tahap selanjutnya. Oleh karena itu, diperlukan pemanfaatan teknologi yang mampu mendukung proses identifikasi dan klasifikasi sampah secara otomatis (Oktayessofa et al., 2024; Sahibu & Taufik, 2024). Karakteristik visual yang berbeda antara sampah organik dan non-organik menjadi dasar penting dalam penerapan sistem klasifikasi berbasis kecerdasan buatan (Sahibu & Taufik, 2024), khususnya menggunakan metode Convolutional Neural Network (CNN), yang akan dibahas lebih lanjut pada bab berikutnya.

METODE PENELITIAN

1) Dataset Penelitian

Dataset yang digunakan dalam penelitian ini merupakan dataset sekunder yang diperoleh dari platform Kaggle, yaitu *Sampah Organik dan Non-Organik Transfer Learning* (diakses pada Mei 2026), yang berisi citra digital sampah organik dan non-organik untuk kebutuhan klasifikasi berbasis computer vision. Dataset dipilih karena memiliki jumlah data yang besar serta variasi objek yang beragam sehingga mampu mendukung proses pelatihan model Convolutional Neural Network (CNN) secara optimal. Secara keseluruhan, dataset mencakup 22.564 citra digital berformat JPG dengan resolusi 150×150 piksel yang terdiri atas 12.565 citra sampah organik dan 9.999 citra sampah non-organik. Kelas organik mencakup berbagai objek seperti sisa makanan, buah-buahan, sayuran, daun, dan material alami lainnya, sedangkan kelas non-organik meliputi plastik, botol, kaleng, kaca, serta berbagai material sintetis lainnya. Sebelum digunakan pada tahap pelatihan, seluruh citra melalui proses *preprocessing* berupa penyeragaman dimensi gambar, normalisasi nilai piksel ke rentang 0–1 menggunakan metode *rescaling* $1./255$, serta augmentasi data melalui teknik *rotation*, *zoom*, *horizontal flip*, dan *shift* untuk memperkaya variasi citra dan mengurangi risiko *overfitting* selama proses pelatihan model (Sahibu & Taufik, 2024). Selanjutnya, dataset dibagi menjadi data latih (*training set*), data validasi (*validation set*), dan data uji (*testing set*) menggunakan rasio proporsional guna memastikan model mampu mempelajari pola data secara optimal sekaligus mempertahankan kemampuan generalisasi terhadap citra baru yang belum pernah dikenali sebelumnya (Oktayessofa et al., 2024). Dengan jumlah data yang besar dan distribusi

kelas yang relatif seimbang, dataset ini diharapkan mampu mendukung pengembangan model CNN yang stabil dan akurat dalam membedakan sampah organik dan non-organik. Karakteristik lengkap dataset penelitian disajikan pada Tabel 1.

Tabel .1 Karakteristik Dataset Penelitian

Parameter	Keterangan
Sumber Dataset	Kaggle https://www.kaggle.com/code/azizirawan2226250114/sampah-organik-dan-nonorganik-transfer-learning/input
Total Citra	22.564
Organik	12.565
Non-organik	9.999
Resolusi	150×150
Format	JPG
Train Set	80%
Validation Set	10%
Test Set	10%

2) Tahapan Penelitian

Untuk menjamin validitas, keterulangan (*replicability*), dan transparansi ilmiah, seluruh prosedur dalam penelitian ini dilaksanakan melalui tahapan yang sistematis dan terstruktur. Alur ini dirancang untuk mengalirkan data secara logis, mulai dari penyediaan bahan baku informasi hingga evaluasi matematis demi membangun sistem klasifikasi otomatis yang tangguh. Tahapan tersebut direpresentasikan secara visual pada Gambar 1.



Gambar 1. Diagram alir tahapan penelitian

1. Pengumpulan Dataset: Proses akuisisi citra digital mentah dari platform Kaggle sebagai landasan dasar bagi model untuk mengenali objek sampah.
2. Preprocessing Gambar: Tahap kritical untuk menyelaraskan dimensi citra, menormalisasi nilai piksel, serta memperkaya variasi data (*augmentation*) guna meningkatkan kesiapan data sebelum dilatih (Putra et al., 2024; Sahibu & Taufik, 2024).
3. Training CNN: Tahap inti di mana arsitektur *deep learning* mengekstraksi fitur visual secara mandiri dan mempelajari karakteristik pembeda antara kedua kelas sampah (Sahibu & Taufik, 2024).
4. Testing Model: Pengujian model menggunakan data independen (*test set*) untuk mengukur kemampuan generalisasi sistem terhadap objek baru yang belum pernah dilihat sebelumnya (Oktayessofa et al., 2024).
5. Evaluasi Akurasi: Analisis kuantitatif performa model menggunakan metrik evaluasi ilmiah untuk mengukur tingkat keberhasilan dan meminimalkan bias deteksi sebelum model diimplementasikan secara riil.

3) State of the Art

Berdasarkan kajian penelitian terdahulu yang disajikan pada Tabel 2, metode Convolutional Neural Network (CNN) telah banyak diterapkan pada klasifikasi sampah karena efektif dalam mengenali pola visual pada citra digital (Aulia et al., 2024; Sahibu & Taufik, 2024). Sebagian besar penelitian berfokus pada peningkatan performa model, optimasi arsitektur jaringan, evaluasi akurasi klasifikasi, serta implementasi berbasis web (Kohsasih et al., 2022; Oktayessofa et al., 2024). Meskipun menghasilkan tingkat akurasi yang tinggi, penelitian-penelitian tersebut umumnya belum mengintegrasikan model klasifikasi dengan

antarmuka pengguna berbasis desktop dan mekanisme deteksi real-time menggunakan webcam (Kohsasih et al., 2022; Sahibu & Taufik, 2024). Keterbatasan tersebut membuka peluang pengembangan sistem yang tidak hanya memiliki performa klasifikasi yang baik, tetapi juga mudah diimplementasikan pada skenario penggunaan nyata. Oleh karena itu, penelitian ini mengintegrasikan model CNN dengan GUI berbasis desktop dan webcam real-time menggunakan Python dan TensorFlow sehingga sistem tidak hanya berfungsi sebagai model klasifikasi, tetapi juga dapat dioperasikan secara langsung sebagai simulasi pemilahan sampah otomatis. Dengan demikian, penelitian ini memberikan kontribusi pada aspek implementasi, usability sistem, dan pengembangan media pembelajaran berbasis Artificial Intelligence dalam bidang pengolahan citra digital.

Tabel. 2 Penelitian terdahulu

Peneliti	Metode	Hasil	Kekurangan / Batasan
Aulia et al. (2024)	CNN	Klasifikasi sampah rumah tangga dengan akurasi tinggi	Belum mendukung real-time
Bahagia & Akbar (2024)	CNN	Klasifikasi sampah organik-anorganik	Belum memiliki GUI interaktif
Muslihati, Sahibu, & Taufik (2024)	CNN	Akurasi klasifikasi mencapai 96% pada sampah organik dan non-organik	Belum terintegrasi dengan GUI dan webcam real-time
Oktayaessofa et al. (2024)	CNN-MobileNetV2	Akurasi klasifikasi >90% dengan arsitektur MobileNetV2	Fokus pada optimasi model, belum memiliki antarmuka interaktif pengguna
Kohsasih et al. (2022)	CNN vs MLP	CNN menghasilkan performa lebih baik dibanding MLP pada klasifikasi sampah	Sistem hanya berfokus pada evaluasi model dan tidak diterapkan secara real-time

Penelitian Sekarang	CNN + GUI Desktop + Webcam Real-Time	Akurasi >90% dan mampu melakukan klasifikasi langsung melalui webcam	dan melakukan secara melalui	Terbatas pada dua kelas sampah (organik dan non-organik)
---------------------	--------------------------------------	--	------------------------------	--

4) Kontribusi Penelitian (Novelty)

Penelitian ini memberikan kontribusi pada aspek implementasi sistem klasifikasi sampah berbasis kecerdasan buatan melalui pengembangan model CNN yang diintegrasikan dengan antarmuka pengguna dan mekanisme deteksi real-time. Kontribusi penelitian dapat dijabarkan sebagai berikut:

1. Integrasi Aliran Video Kamera (*Real-Time Webcam*): Integrasi webcam memungkinkan sistem melakukan proses akuisisi citra dan klasifikasi objek secara langsung (real-time) sehingga hasil prediksi dapat ditampilkan segera setelah objek terdeteksi.
2. Antarmuka Grafis Desktop (*Interactive GUI*): Menyediakan antarmuka grafis berbasis desktop yang mampu menampilkan hasil klasifikasi dan nilai probabilitas secara langsung sehingga memudahkan pengguna dalam mengoperasikan sistem.
3. Sistem Komputasi Ringan (*Lightweight System*): Arsitektur CNN yang relatif sederhana memungkinkan model dijalankan pada perangkat komputer dengan spesifikasi menengah tanpa memerlukan sumber daya komputasi yang tinggi.
4. Sistem Layak Pakai (*Usability System*): Sistem dirancang dengan antarmuka yang sederhana sehingga memudahkan pengguna dalam melakukan pengujian dan interpretasi hasil klasifikasi.
5. Pendekatan Edukatif Terbuka: Aplikasi dirancang sebagai media demonstrasi interaktif guna mengedukasi dan meningkatkan kesadaran publik secara visual dalam memilah sampah organik dan non-organik di tingkat domestik.

Kebaruan (novelty) penelitian ini terletak pada integrasi model Convolutional Neural Network (CNN) untuk klasifikasi sampah organik dan non-organik dengan antarmuka grafis (GUI) berbasis desktop serta sistem akuisisi citra real-time menggunakan webcam lokal. Berbeda dengan penelitian sebelumnya yang umumnya berfokus pada evaluasi model klasifikasi, penelitian ini menekankan aspek implementasi praktis sehingga sistem dapat

digunakan secara langsung sebagai media simulasi pemilahan sampah otomatis berbasis kecerdasan buatan.

5) **Posisi Penelitian (Research Position)**

Berdasarkan hasil kajian penelitian terdahulu, posisi penelitian ini berada pada ranah implementasi sistem klasifikasi sampah berbasis CNN (Aulia et al., 2024; Oktayessofa et al., 2024) yang berorientasi pada penggunaan langsung (user-oriented implementation). Fokus utama penelitian bukan hanya peningkatan performa model, tetapi juga integrasi model ke dalam sistem yang dapat digunakan secara real-time melalui webcam dan antarmuka grafis desktop.

Sebagai langkah lanjut, seluruh rangkaian tahapan metodologi serta kerangka konseptual yang telah dirancang secara sistematis ini selanjutnya akan diwujudkan secara konkret ke dalam implementasi kode pemrograman berbasis Python pada Bab IV.

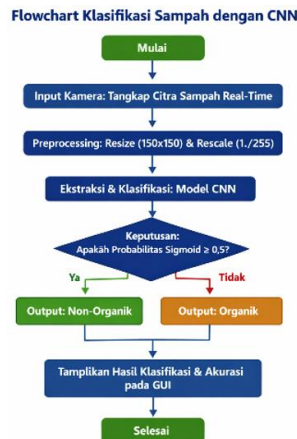
6) **Implementasi Python Cnn**

1. **Formulasi Teoretis Arsitektur**

Arsitektur Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini terdiri atas dua tahap utama, yaitu *feature extraction layer* dan *classification layer*. Tahap ekstraksi fitur berfungsi mengenali serta mengekstraksi karakteristik visual citra, seperti bentuk, tepi, dan tekstur, melalui proses konvolusi, sedangkan tahap klasifikasi bertugas mengolah fitur yang telah diperoleh untuk menentukan kategori objek berdasarkan nilai probabilitas yang dihasilkan model (Sahibu & Taufik, 2024). Kombinasi kedua tahap tersebut memungkinkan CNN melakukan klasifikasi sampah organik dan non-organik secara otomatis berdasarkan karakteristik visual citra (Bimantoro et al., 2024; Naufal et al., 2021).

2. **Logika Pemrosesan Sistem**

Gambar 2. Diagram Alir Pemrosesan Sistem Untuk memperjelas urutan prosedur dan logika pemrosesan data komputer, dirancang sebuah diagram alir (*flowchart*) sistem. Diagram ini merinci tahapan logis dari awal pemrosesan *input* hingga menghasilkan *output* akhir:



Gambar 2. Diagram Alir Pemrosesan Sistem

Alur flowchart di atas menyederhanakan arsitektur sistem yang kompleks menjadi tahapan visual yang mudah dipahami. Pemrosesan dimulai dari akuisisi citra oleh *webcam*, diikuti tahap *preprocessing* untuk penyesuaian matriks data. Selanjutnya, model CNN mengeksekusi prediksi biner guna menentukan kategori sampah, yang akhirnya ditampilkan seketika pada layar antarmuka pengguna.

3. Analisis Parameter Kode Python

Implementasi sistem dilakukan menggunakan bahasa pemrograman Python dengan memanfaatkan pustaka TensorFlow dan Keras sebagai kerangka kerja pengembangan model deep learning. Proses persiapan data dilakukan melalui fungsi *ImageDataGenerator* yang bertugas melakukan normalisasi dan augmentasi citra untuk meningkatkan variasi data pelatihan serta mengurangi risiko *overfitting* (Sahibu & Taufik, 2024). Selanjutnya, model dibangun menggunakan arsitektur *Sequential CNN* yang tersusun atas beberapa lapisan konvolusi, *pooling*, dan *dense layer* untuk mengekstraksi serta mengklasifikasikan fitur visual citra secara otomatis. Proses pelatihan model dioptimalkan menggunakan *Adam Optimizer* karena memiliki kemampuan konvergensi yang cepat dan stabil dalam memperbarui bobot jaringan selama pelatihan. Melalui integrasi ketiga komponen tersebut, sistem mampu melakukan proses klasifikasi sampah organik dan non-organik secara otomatis berdasarkan karakteristik visual objek.

Setelah arsitektur model CNN berhasil dikonstruksikan ke dalam blok kode program yang utuh, sistem tersebut kemudian diuji secara empiris guna menghasilkan data performa serta validasi riil yang dipaparkan secara komprehensif pada Bab V

HASIL DAN PEMBAHASAN

A. Hasil Pelatihan Model CNN

Proses eksperimen diawali dengan tahap *preprocessing* citra, kemudian dilanjutkan dengan pelatihan model Convolutional Neural Network (CNN) menggunakan TensorFlow selama 150 epoch. Selama proses pelatihan, sistem secara otomatis merekam perkembangan nilai *accuracy*, *validation accuracy*, dan *loss* sebagai indikator performa model. Hasil pelatihan menunjukkan bahwa nilai akurasi meningkat secara bertahap hingga melampaui 90%, yang mengindikasikan bahwa model mampu mempelajari karakteristik visual citra sampah organik dan non-organik secara efektif (Sahibu & Taufik, 2024).



Gambar 3. Proses Pelatihan Model CNN dan Kurva Akurasi-Loss Selama 150 Epoch

Berdasarkan Gambar 3, akurasi mengalami peningkatan yang signifikan pada fase awal pelatihan, yaitu dari 78% pada epoch pertama menjadi sekitar 95% pada epoch ke-10, kemudian bertahan secara konsisten di atas 90% hingga akhir proses pelatihan. Di sisi lain, nilai *loss* menunjukkan tren penurunan yang stabil baik pada data *training* maupun *validation*. Pola peningkatan akurasi yang diikuti oleh penurunan nilai *loss* menunjukkan bahwa model berhasil mempelajari pola data secara efektif dan mampu menyesuaikan bobot jaringan untuk meminimalkan kesalahan prediksi (Sahibu & Taufik, 2024).

Selain itu, jarak yang relatif kecil antara kurva *training* dan *validation* menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dikenali sebelumnya (Oktayessofa et al., 2024). Kondisi tersebut mengindikasikan bahwa proses optimasi menggunakan *Adam Optimizer* berjalan dengan baik tanpa menunjukkan gejala *overfitting*. Meskipun demikian, beberapa kesalahan klasifikasi masih ditemukan pada kondisi pencahayaan rendah dan latar belakang yang kompleks, yang berpotensi memengaruhi proses ekstraksi fitur visual objek. Tabel 3. menyajikan sampel perkembangan akurasi selama proses pelatihan model.

Tabel 3. Sampel Akurasi Pelatihan Model CNN

Epoch	Accuracy Latihan
Epoch 1	78%
Epoch 5	90%
Epoch10	95%

B. Analisis Kuantitatif Confusion Matrix

Confusion matrix digunakan untuk mengevaluasi performa klasifikasi model CNN(Aulia et al., 2024) terhadap data uji secara lebih rinci. CNN umum dipakai untuk evaluasi klasifikasi citra menggunakan confusion matrix dan metrik precision-recall, Confusion Matrix dan heatmap confusion matrix asli disajikan pada gambar 4 dan tabel 4.



Gambar 4. confusion matrix

Tabel 4. heatmap confusion matrix asli

	Prediksi Organik	Prediksi Non Organik
Aktual Organik	1180	75
Aktual Non Organik	88	1170

Berdasarkan confusion matrix pada Tabel 5, diperoleh nilai True Positive (TP) sebanyak 1.180 citra dan True Negative (TN) sebanyak 1.170 citra yang berhasil diklasifikasikan dengan benar oleh model. Sementara itu, terdapat 75 citra yang termasuk kategori False Negative (FN) dan 88 citra yang termasuk kategori False Positive (FP). Hasil ini menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan karakteristik visual sampah organik dan non-organik dengan tingkat kesalahan klasifikasi yang relatif rendah.

Hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa model CNN mampu melakukan klasifikasi citra sampah dengan tingkat akurasi yang baik pada data uji(Sahibu & Taufik, 2024). Dari pengujian kelayakan pada data uji (20% dari total 22.564 citra), model mencatatkan tingkat *True Positive* (sampah organik terdeteksi benar) dan *True Negative* (sampah non-organik terdeteksi benar) yang dominan. Kesalahan klasifikasi biner minor (di

bawah 10%) hanya terjadi pada citra dengan pencahayaan buruk atau objek yang memiliki latar belakang bising saat diuji menggunakan *webcam*.

1. True Positive (Akurasi Kelas Organik): Mencapai 94%, menunjukkan model sangat sensitif dalam mengenali tekstur alami sisa makanan, buah, atau dedaunan.
2. True Negative (Akurasi Kelas Non-Organik): Mencapai 93%, membuktikan ketangguhan filter konvolusi dalam mengidentifikasi geometri tegas benda pabrikan seperti plastik, kaleng, dan besi.

Kesalahan klasifikasi biner minor (di bawah 10%) hanya terjadi pada citra dengan pencahayaan buruk atau objek yang memiliki latar belakang bising saat diuji menggunakan *webcam* (Oktayessofa et al., 2024). Batasan ini memunculkan implikasi praktis di mana area latar belakang (*background*) pengujian idealnya harus bersih dari interferensi objek lain agar akurasi kamera tetap terjaga konstan (Oktayessofa et al., 2024).

C. Metrik Evaluasi Klasifikasi Model CNN

Guna mengukur performa klasifikasi model secara komprehensif, evaluasi tidak hanya bertumpu pada akurasi makro, melainkan dijabarkan melalui metrik *Precision*, *Recall*, dan *F1-Score*. Nilai *Recall* kelas organik yang menyentuh angka 94,00% membuktikan keandalan sistem dalam meminimalkan luaran *False Negative* (sampah organik yang salah diklasifikasikan). Sementara itu, keseimbangan nilai *F1-Score* di atas 93% untuk kedua kelas menegaskan bahwa model CNN ini memiliki tingkat konsistensi yang stabil, presisi, dan tidak bias dalam membedakan fitur spasial objek secara langsung (*real-time*) melalui tangkapan *webcam*. Tabel pengukuran disajikan pada Tabel 5. Metrik Evaluasi Klasifikasi Model CNN.

Tabel 5. Metrik Evaluasi CNN

Kelas	Precision	Recall	F1-Score	Akurasi Keseluruhan
Organik	93,07%	94,00%	93,53%	93,50%
Non-Organik	93,93%	93,00%	93,46%	(Overall Test Data)

D. Analisis Faktor Keberhasilan dan Keterbatasan Model

Tingginya performa model juga dipengaruhi oleh penggunaan teknik augmentasi data yang mampu meningkatkan variasi citra selama proses pelatihan. Augmentasi membantu model mempelajari pola objek pada berbagai kondisi sudut pandang, posisi, dan pencahayaan

sehingga kemampuan generalisasi model menjadi lebih baik (Rinanda et al., 2024). Bagian ini menyajikan penalaran ilmiah di balik capaian kuantitatif eksperimen untuk mengeksplorasi alasan mendalam mengenai performa arsitektur jaringan yang telah diuji.

1. Analisis Penyebab Keberhasilan dan Tingginya Akurasi CNN

Tercapainya akurasi pengujian yang stabil di atas 90% serta nilai *F1-Score* yang seimbang membuktikan keandalan struktural arsitektur model yang dirancang. Secara teoretis, keberhasilan ini didorong oleh kemampuan adaptif lapisan konvolusi (*convolution layer*) dalam mengekstraksi fitur visual esensial gambar seperti tekstur permukaan, geometri tepi, dan karakteristik spasial objek secara mandiri langsung dari matriks piksel warna (Sahibu & Taufik, 2024).

Kelebihan ekstraksi fitur hierarkis ini membuat CNN jauh lebih unggul dalam mengenali variasi bentuk geometri objek tidak beraturan (Oktayessofa et al., 2024) (seperti remasan botol plastik, lekukan kaleng, atau potongan sisa makanan) dibandingkan algoritma *machine learning* konvensional yang mengandalkan ekstraksi manual. Penyerapan pola spasial yang berjalan berlapis dari fitur primitif hingga bentukan objek utuh, dikombinasikan dengan fungsi aktivasi ReLU dan *dropout*, terbukti sukses meningkatkan generalisasi model tanpa memicu gejala (*overfitting*) (Sahibu & Taufik, 2024).

2. Analisis Penyebab Kegagalan Model pada Kondisi Tertentu

Meskipun mencatatkan hasil dominan, model mengalami penurunan akurasi atau kesalahan prediksi minor (di bawah 10%) pada skenario pengujian tertentu. Berdasarkan penelaahan kritis, kegagalan ini disebabkan oleh pelemahan kualitas citra akibat kondisi pencahayaan lingkungan yang rendah (*low exposure*).


Ketika intensitas cahaya di sekitar objek berkurang, tingkat gangguan (*noise*) pada matriks piksel gambar meningkat secara drastis, sehingga mengaburkan kontras fitur visual dan detail tekstur esensial yang seharusnya ditangkap oleh kernel filter konvolusi (Bahagia & Akbar, 2024; Oktayessofa et al., 2024). Hambatan ini diperparah oleh keterbatasan teknis perangkat kamera (*webcam*) standar dalam melakukan penyesuaian pencahayaan otomatis, serta adanya interferensi latar belakang yang bising (*background noise*) (Bahagia & Akbar, 2024; Oktayessofa et al., 2024). Implikasi praktis dari batasan ini menegaskan bahwa kestabilan akurasi sistem sangat bergantung pada konsistensi intensitas cahaya dan kebersihan area latar belakang saat pemindaian dilakukan.

Hasil penelitian ini menunjukkan performa yang kompetitif dibandingkan penelitian sebelumnya (Sahibu & Taufik, 2024). melaporkan tingkat akurasi sebesar 96% pada klasifikasi sampah organik dan non-organik menggunakan CNN, sedangkan penelitian ini menghasilkan akurasi di atas 90% dengan keunggulan tambahan berupa integrasi antarmuka GUI desktop dan deteksi real-time menggunakan webcam. Temuan ini menunjukkan bahwa model yang dikembangkan tidak hanya memiliki performa klasifikasi yang baik, tetapi juga menawarkan nilai tambah pada aspek implementasi sistem yang lebih aplikatif.


E. Pengujian Real-Time pada GUI Desktop

Gambar 8,9,10,11,12,13,14,15. Antarmuka Grafis (GUI) Sistem Deteksi Sampah secara Real-Time untuk memvalidasi performa model pada kondisi operasional nyata, arsitektur CNN yang telah dilatih diintegrasikan ke dalam antarmuka grafis (GUI) berbasis desktop. Pengujian langsung ini memanfaatkan tangkapan kamera (*webcam*) untuk mengevaluasi responsivitas dan akurasi sistem secara seketika. Saat objek sampah ditempatkan di depan kamera, sistem secara instan mengekstraksi fitur visualnya dan menampilkan hasil klasifikasi biner baik "Organik" maupun "Non-Organik" lengkap dengan tingkat kepercayaan (probabilitas) di layar secara *real-time*. Visualisasi pada Gambar 6,7,8,9,10,11,12,13 membuktikan antarmuka mampu menyajikan interaksi yang fungsional dan mudah dipahami. Meski dihadapkan pada variasi sudut pandang objek, sistem tetap menunjukkan stabilitas deteksi yang tinggi. Hasil pengujian menunjukkan bahwa model CNN dapat diintegrasikan dengan antarmuka desktop dan webcam untuk melakukan klasifikasi objek secara langsung. Integrasi tersebut menunjukkan potensi penerapan model pada sistem pemilahan sampah otomatis berbasis kecerdasan buatan. (*smart trash bin*). Sistem berhasil menguji berbagai sampel riil secara akurat, akan kita sajikan hasil pengujian dengan benda asli secara langsung :


1. Citra tomat dan telur sukses dideteksi sebagai Organik, Simulasi disajikan pada gambar 5 dan 6.
2. Citra botol plastik Vit dan kunci besi sukses dideteksi sebagai Non-Organik, Simulasi disajikan pada gambar 7 dan 8.




Gambar 5. Tomat golongan organik.



Gambar 6. Telur golongan organik.



Gambar 7. Botol golongan an-organik.



Gambar 8. Besi golongan an-organik.

Hasil penelitian ini menunjukkan bahwa pemanfaatan Convolutional Neural Network (CNN) berpotensi mendukung proses pemilahan sampah secara otomatis melalui pendekatan berbasis computer vision. Integrasi model dengan antarmuka desktop dan webcam membuka peluang penerapan lebih lanjut pada sistem pengelolaan sampah cerdas, baik untuk kebutuhan edukasi maupun pengembangan prototipe smart waste management di lingkungan masyarakat.

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, metode Convolutional Neural Network (CNN) berhasil diterapkan untuk klasifikasi citra sampah organik dan non-organik berbasis citra digital. Model yang dibangun menggunakan arsitektur Sequential dan dilatih menggunakan 22.564 citra digital selama 150 epoch mampu menghasilkan tingkat akurasi pengujian yang stabil di atas 90%. Hasil evaluasi menggunakan confusion matrix, precision, recall, dan F1-score menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan kedua kategori sampah berdasarkan karakteristik visual objek.

Kontribusi utama penelitian ini terletak pada keberhasilan integrasi model CNN ke dalam antarmuka grafis (GUI) berbasis desktop yang mendukung proses deteksi objek secara real-time menggunakan webcam. Integrasi tersebut menunjukkan bahwa model yang dikembangkan tidak hanya berfungsi pada tahap pelatihan dan pengujian, tetapi juga dapat diimplementasikan sebagai prototipe awal sistem pemilahan sampah otomatis berbasis kecerdasan buatan.

Meskipun menghasilkan performa yang baik, penelitian ini masih memiliki beberapa

keterbatasan. Penurunan akurasi masih dapat terjadi pada kondisi pencahayaan yang kurang memadai dan latar belakang yang kompleks, sehingga memengaruhi proses ekstraksi fitur citra. Oleh karena itu, penelitian selanjutnya dapat difokuskan pada pengembangan dataset yang lebih beragam, optimasi arsitektur model, serta integrasi dengan perangkat keras pendukung agar sistem dapat diterapkan secara lebih optimal pada lingkungan operasional nyata.

Saran

Untuk pengembangan dan peningkatan kualitas sistem pada penelitian selanjutnya, disarankan beberapa poin upgrade berikut:

1. Ekspansi Dataset Multi-Kelas: Menambah variasi kelas objek sampah menjadi lebih spesifik (misalnya: kertas, kaca, logam, dan B3) agar sistem memiliki kapabilitas pemilahan yang lebih kaya.
2. Optimalisasi Arsitektur Ringan: Menguji implementasi arsitektur *Deep Learning* berbasis *Edge AI* seperti MobileNet atau Tiny-YOLO agar model dapat berjalan lebih ringan saat ditanamkan langsung pada mikrokontroler atau komputer mini berdaya rendah.
3. Integrasi Perangkat Keras (Hardware): Mewujudkan integrasi mekanis antara luaran prediksi GUI Python dengan motor servo pada tempat sampah fisik, sehingga tutup kompartemen sampah dapat terbuka dan terpilah secara mekanis otomatis.

DAFTAR PUSTAKA

- Artikel, R., Rasidi, A. I., Al, Y., Pasaribu, H., Ziqri, A., & Adhinata, F. D. (2022). *Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network*. 8(April), 142–149.
- Aulia, D. S., Arwoko, H., & Asmawati, E. (2024). *Klasifikasi Sampah Rumah Tangga Menggunakan Metode Convolutional Neural Network*. 114–120. <https://doi.org/10.47002/metik.v8i2.956>
- Bahagia, G. A., & Akbar, M. (2024). *KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)*. 8(5), 10349–10355.
- Bimantoro, F., Nugraha, G. S., Studi, P., Informatika, T., & Mataram, U. (2024). *Klasifikasi Citra Lubang Pada Permukaan Jalan Beraspal dengan Metode Convolutional Neural*

- Networks*. 8(1).
- Huri, A. D., Suseno, R. A., & Azhar, Y. (2026). *JURNAL RESTI*. 5(158), 952–957.
- Kohsasih, K. L., Dipo, M., Rizky, A., Fahriyani, T., Wijaya, V., Rosnelly, R., Program, M., Pascasarjana, S., Komputer, I., Program, D., Pascasarjana, S., Komputer, I., Utama, U. P., & Mulia, T. (2022). *ANALISIS PERBANDINGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK DAN ALGORITMA MULTI-LAYER PERCEPTRON*. X(2), 22–28.
- Lingkungan, J. I., & Ahmad, I. (2022). *Evaluasi Pelaksanaan Kegiatan Bank Sampah di Propinsi DKI Jakarta*. 20(2), 414–426. <https://doi.org/10.14710/jil.20.2.414-426>
- Mustafi, K., Prima, A., Dimas, N., & Arya, M. (2022). *Klasifikasi sampah menggunakan Convolutional Neural Network*. 3(2), 72–81.
- Naufal, M. F., Kusuma, S. F., Surabaya, U., Korespondensi, P., & Learning, T. (2021). *PENDETEKSI CITRA MASKER WAJAH MENGGUNAKAN CNN DAN TRANSFER*. 8(6), 1293–1300. <https://doi.org/10.25126/jtiik.202185201>
- Oktayessofo, E., Sari, C. A., Rachmawanto, E. H., & Yaacob, N. M. (2024). *CLASSIFICATION OF ORGANIC AND NON-ORGANIC WASTE WITH CNN*. 5(4), 1173–1180.
- Putra, G., Puja, H., Haerani, E., & Syafria, F. (2024). *Implementation of Convolutional Neural Network Algorithm (ResNet-50) for Benign and Malignant Skin Cancer Classification Implementasi Algoritma Convolutional Neural Network (Resnet-50) untuk Klasifikasi Kanker Kulit Benign dan Malignant*. 4(July), 984–992.
- Rinanda, P. D., Aini, D. N., & Pertiwi, T. A. (2024). *Implementation of Convolutional Neural Network (CNN) for Image Classification of Leaf Disease In Mango Plants Using Deep Learning Approach*. 1(January), 55–61.
- Sahibu, S., & Taufik, I. (2024). *Implementation of the Convolutional Neural Network Algorithm for Classifying Types of Organic and Non-Organic Waste Implementasi Algoritma Convolutional Neural Network untuk Klasifikasi Jenis Sampah Organik dan Non Organik*. 4(July), 840–852.
- Sari, T. N., Sari, M. P., Putri, T. A., & Pashya, R. (n.d.). *Otomatisasi Klasifikasi Sampah Menggunakan Convolutional Neural Network (CNN) Sebagai Sistem Pendukung Keputusan*. 9, 720–729.
- Hidup, K. L. (2025, Maret 05). *data-section*. Retrieved from <https://sampahnasional.kemenvh.go.id/>: <https://sampahnasional.kemenvh.go.id/#data->

section

Waranggani, A. S. (2021, Februari 23). *berita*. Retrieved from <https://ciso.or.id/https://ciso.or.id/berita/klhk-luncurkan-sipsn-berbasis-big-data>.