

# Sistem Deteksi Sampah Menggunakan Arsitektur Alexnet dan Contour

Muhammad Raqil Salman Alfarisi<sup>1</sup>, Wina Witanti<sup>2</sup>, Edvin Ramadhan<sup>3</sup>

Fakultas Sains dan Informatika/Program Studi Informatika  
Universitas Jenderal Achmad Yani  
Cimahi, Indonesia

e-mail: <sup>1</sup>raqiljenglot@gmail.com, <sup>2</sup>witanti@gmail.com, <sup>3</sup>edvin.ramadhan@lecture.if.unjani.ac.id

Correspondence : [raqiljenglot@gmail.com](mailto:raqiljenglot@gmail.com)

Diajukan: 15 Agustus 2024; Direvisi: 23 Agustus 2024; Diterima: 25 Agustus 2024

## Abstrak

Di Indonesia, masalah sampah semakin serius seiring dengan pertumbuhan penduduk. Data dari Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) 2021 menunjukkan total sampah mencapai 24,67 juta ton per tahun, meskipun terjadi penurunan 13,38% dari tahun sebelumnya. Penelitian ini menggunakan Convolutional Neural Network (CNN) dengan arsitektur AlexNet untuk mendeteksi jenis sampah melalui analisis citra. Proses mencakup preprocessing gambar, pembangunan arsitektur AlexNet, pelatihan model untuk membedakan jenis sampah, dan evaluasi kinerja dengan metrik seperti akurasi, presisi, recall, dan F1 score. Hasil menunjukkan model CNN dengan AlexNet mencapai akurasi pelatihan 92,97% dan validasi 78,57%, dengan nilai presisi 0,8303, recall 0,9157, dan F1 score 0,8709. Evaluasi menunjukkan bahwa metode CNN dengan AlexNet dapat meningkatkan efisiensi dan efektivitas pengolahan sampah, menawarkan potensi pengembangan sistem pengelolaan sampah yang lebih cerdas, termasuk dengan integrasi deteksi kontur menggunakan OpenCV.

**Kata kunci:** Sampah, organik dan anorganik, Convolutional Neural Network, AlexNet, DeepLearning, Contour

## Abstract

In Indonesia, the waste problem is intensifying with population growth. Data from the National Waste Management Information System (SIPSN) in 2021 shows that total waste generation reached 24.67 million tons per year, despite a 13.38% decrease from the previous year. This study employs a Convolutional Neural Network (CNN) with the AlexNet architecture for waste type detection through image analysis. CNNs are adept at recognizing patterns in visual data, such as images. The dataset includes both organic and inorganic waste. The research involves image preprocessing, building the AlexNet architecture, training the model, and evaluating its performance using metrics like accuracy, precision, recall, and F1 score. Results indicate that the CNN model with AlexNet achieves a training accuracy of 92.97% and validation accuracy of 78.57%, with precision, recall, and F1 scores of 0.8303, 0.9157, and 0.8709, respectively. This evaluation demonstrates that CNN with AlexNet can enhance the efficiency and effectiveness of waste management through precise automation, particularly in waste type detection. The findings suggest potential for developing more intelligent waste management systems, integrating OpenCV contour detection for improved accuracy.

**Keywords:** Waste, organic and recyclable, Convolutional Neural Network, AlexNet, DeepLearning, Contour.

## 1. Pendahuluan

Di Indonesia, masalah sampah semakin serius seiring pertumbuhan penduduk. Menurut data Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) tahun 2021, jumlah sampah yang dihasilkan mencapai 24,67 juta ton per tahun, dengan hanya sekitar 50,43% atau 12,44 juta ton yang berhasil dikelola dengan baik, meskipun ada penurunan total sampah sebesar 13,38% dibandingkan tahun sebelumnya [1]. Setiap hari, Indonesia menghasilkan sekitar 67.590 ton sampah atau 0,25 kg per orang, menunjukkan krisis sampah yang membutuhkan perhatian serius. Berdasarkan Undang-Undang Republik Indonesia Nomor 18 Tahun 2008, sampah didefinisikan sebagai sisa aktivitas manusia atau proses alam yang berbentuk padat [2]. Penelitian ini fokus pada klasifikasi citra sampah menggunakan Convolutional Neural Network (CNN)

dengan beberapa lapisan konvolusi 2D dan *fully connected*. Dalam penelitian ini, model dengan resolusi gambar lebih rendah (80x45) mencapai akurasi 80,88%, mengungguli model dengan resolusi lebih tinggi (225x264) yang mencapai akurasi 76,19%, dan keduanya melampaui baseline sebesar 50,05% [3]. Penambahan *hyperparameter* seperti *dropout*, *padding*, dan *stride* pada CNN meningkatkan akurasi hingga 91,2%, memberikan peningkatan signifikan sebesar 20% dibandingkan model tanpa *hyperparameter*, dan berkontribusi penting dalam pengembangan teknologi pengenalan sampah berbasis citra [4].

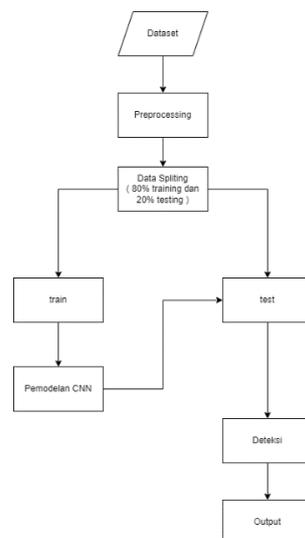
Pada penelitian sebelumnya mengenai klasifikasi sampah dengan menggunakan metode *Convolutional Neural Network* (CNN) telah menunjukkan hasil yang sangat menjanjikan. CNN berhasil diimplementasikan untuk mengklasifikasikan objek sampah seperti plastik, botol, dan kaleng, dengan tujuan untuk mengurangi volume sampah di Indonesia. Hasil penelitian ini menunjukkan bahwa CNN mampu mengklasifikasikan sampah organik dengan akurasi yang sangat tinggi. Temuan ini memberikan dasar yang kuat untuk mengembangkan sistem kecerdasan buatan yang dapat secara otomatis mengidentifikasi dan mengklasifikasikan jenis sampah, serta berkontribusi pada upaya implementasi AI dalam pengelolaan sampah [5]. Untuk mengembangkan sistem klasifikasi sampah yang cerdas. Sistem ini dirancang untuk mengotomatiskan proses pemilahan sampah dengan mengkategorikan berbagai jenis sampah secara akurat. Dengan tingkat akurasi yang umumnya mencapai sekitar 87%, sistem ini memiliki potensi untuk mengurangi keterlibatan manusia dalam pengelolaan sampah dan meningkatkan efisiensi secara keseluruhan [6]. Menerapkan arsitektur *AlexNet* dan *Resnet34* dengan teknik *transfer learning* untuk klasifikasi citra, dengan 3.300 citra yang terbagi menjadi 3 kategori menunjukkan bahwa *Alexnet* dapat mencapai akurasi 98% setelah 16 epoch dengan batch size 14, sementara *Resnet* mencapai akurasi 99% dengan konfigurasi yang sama [7].

*Convolutional Neural Network* untuk klasifikasi jenis sampah, menemukan bahwa CNN menghasilkan performa yang lebih unggul mencapai 0.98. Menerapkan CNN dengan metode *transfer learning* menggunakan model *pre-trained* dari *ImageNet* memperoleh akurasi pelatihan yang tinggi [8]. Model CNN seperti *VGG16* dan *AlexNet* dapat mencapai tingkat akurasi hingga 93% dan 91% sehingga mampu mengidentifikasi dan mengklasifikasikan sampah [9]. *AlexNet* digunakan untuk klasifikasi sampah berdasarkan status daur ulang, dan mencapai hasil yang menjanjikan dalam pengelolaan limbah [10].

Berdasarkan latar belakang yang telah diuraikan, dengan menggunakan metode *Convolutional Neural Network* diharapkan dapat melakukan identifikasi yang meliputi deteksi dan klasifikasi jenis sampah. Hal ini dilakukan dengan mengkonfigurasi *hyperparameter* pada arsitektur CNN, seperti *dropout*, *padding*, dan *stride* untuk meningkatkan akurasi dalam mendeteksi jenis sampah.

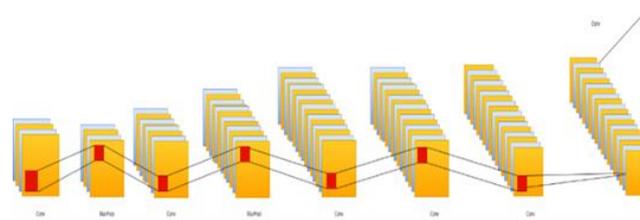
## 2. Metode Penelitian

Metode penelitian ini menjelaskan secara sistematis sehingga penelitian dapat dirancang dengan baik. Penelitian ini menggunakan metode *Convolutional Neural Network*, sebuah teknik dalam bida deep learning yang dirancang untuk menganalisis pola dalam data visual. CNN bekerja dengan mengonvolusi input gambar melalui beberapa lapisan, seperti lapisan konvolusi, *pooling*, dan *fully connected* untuk menghasilkan prediksi untuk deteksi. Tahapan penelitian yang akan dilakukan adalah sebagai berikut:



Gambar 1. Metode Penelitian

Diagram di atas menjelaskan tentang alur penelitian yang dilakukan. Proses dimulai dengan pengumpulan dataset yang kemudian melalui tahap *preprocessing* untuk membersihkan dan mempersiapkan data. Selanjutnya, data dibagi menjadi dua bagian dengan data splitting, yaitu 80% untuk pelatihan *training* dan 20% untuk pengujian *testing*. Data training digunakan untuk pemodelan CNN sementara data *testing* digunakan untuk menguji model dalam *fase test*. Hasil dari pengujian ini menghasilkan deteksi yang kemudian memberikan *output* akhir dari sistem.

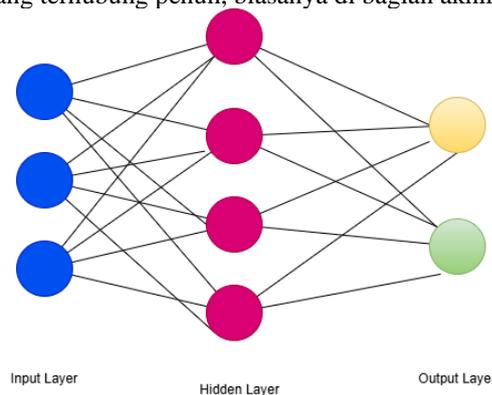


Gambar 2 Arsitektur AlexNet

Arsitektur jaringan saraf *convolutional* AlexNet, yang merupakan salah satu model pembelajaran mendalam yang berpengaruh di bidang visi komputer. AlexNet terdiri dari beberapa lapisan konvolusi yang diikuti oleh lapisan penyatuan. Lapisan-lapisan ini berfungsi untuk mengekstrak fitur dari gambar input melalui proses konvolusi dan *downsampling*. Model ini dikenal karena keberhasilannya dalam kompetisi *ImageNet*, di mana model ini secara signifikan mengungguli model-model sebelumnya dalam hal akurasi pengenalan gambar. Keunggulan utama AlexNet termasuk penggunaan *Rectified Linear Units* (ReLU) sebagai fungsi aktivasi dan melatih model dengan data yang ditambah untuk mengurangi *overfitting*.

*Convolutional layer* adalah lapisan yang terdiri dari matriks persegi panjang neuron. Bobot konvolusi mewakili saluran konvolusi, dan konvolusi menghitung neuron yang terhubung ke lapisan input. Setiap neuron terhubung ke bobot dan wilayah kecil yang terhubung dengannya di lapisan input. Kendala yang dihadapi oleh lapisan konvolusi adalah untuk mencapai generalisasi yang lebih baik dalam bidang visi computer.

Lapisan konvolusi (*convolutional layer*) menggunakan *filter* (kernel) yang bergerak melintasi gambar input untuk menghasilkan peta fitur (*feature map*), di mana setiap *filter* mendeteksi pola tertentu seperti tepi, tekstur, atau bentuk. Lapisan pooling, seperti *max pooling* dan *average pooling*, berfungsi mengurangi dimensi data dengan mengambil nilai maksimum atau rata-rata dari blok persegi panjang dalam lapisan konvolusi. Ini membantu mengurangi *overfitting* dan jumlah parameter dalam model, sekaligus mempercepat komputasi sambil menjaga fitur penting dari data. Setelah lapisan pooling, lapisan *Fully Connected* (*Dense Layer*) melanjutkan fungsi aktivasi, di mana keluaran dari lapisan sebelumnya diratakan dan dimasukkan ke dalam layer yang terhubung penuh, biasanya di bagian akhir jaringan CNN.



Gambar 3 Fully Connected Layer

Fungsi aktivasi linear yang banyak digunakan pada CNN adalah ReLU (*Rectified Linear Unit*). Fungsi aktivasi digunakan untuk menentukan apakah suatu neuron harus aktif atau tidak Berdasarkan pada nilai bobot inputnya.

### 3. Hasil dan Pembahasan

#### 3.1. Pengumpulan Data

Data citra sampah yang digunakan dalam penelitian ini diperoleh dari sumber yang terpercaya, yaitu <https://data.mendeley.com/datasets/n3gtgm9jxj/2>. *Dataset* ini terdiri dari citra berwarna dalam format .jpg yang memiliki resolusi dan orientasi yang beragam, sehingga memungkinkan model pembelajaran lebih efektif dalam membedakan dan mengklasifikasikan citra sampah. Hasil pengolahan data, *dataset* dibagi menjadi dua bagian yaitu 80% untuk training set dan 20% untuk *test set*.

#### 3.2. Preprocessing Data

Tahap *preprocessing* data dilakukan sebelum implementasi model klasifikasi sampah. Tahapan ini mencakup pembersihan dan transformasi data, termasuk mengubah ukuran semua gambar menjadi 227x227 piksel agar konsisten sebelum dimasukkan ke dalam model CNN. Selain itu, data augmentasi diterapkan untuk meningkatkan jumlah dan variasi data pelatihan guna mencegah *overfitting* dan meningkatkan kemampuan generalisasi model. Teknik augmentasi yang digunakan meliputi *rescaling*, rotasi, pergeseran lebar dan tinggi, *zoom*, *horizontal flip*, penyesuaian kecerahan, dan pergeseran saluran warna.

#### 3.3. Pembangunan Model *Convolutional Neural Network*

Pada tahap konvolusi, citra dari dataset deteksi sampah yang telah diproses digunakan untuk mengekstraksi fitur-fitur penting seperti bentuk, tekstur, dan tepi, yang penting untuk deteksi sampah. Arsitektur CNN yang digunakan terdiri dari beberapa lapisan konvolusi dan pooling. Lapisan pertama menggunakan 96 *filter* berukuran 11x11 dengan stride 4, diikuti oleh pooling dan dropout. Lapisan kedua memiliki 256 *filter* 5x5 dengan *padding* 'sama', diikuti pooling dan dropout. Lapisan ketiga dan keempat masing-masing menggunakan 384 *filter* 3x3 dengan *padding* 'sama', sementara lapisan kelima menggunakan 256 *filter* 3x3 dengan *padding* 'sama', diikuti pooling dan dropout. Setelah itu, terdapat lapisan *fully connected* dengan 4.096 unit dan dropout, serta lapisan *output* dengan aktivasi sigmoid. Arsitektur ini memungkinkan model untuk secara efektif membedakan berbagai jenis sampah berdasarkan fitur-fitur yang diekstraksi.

#### 3.4. Deteksi *Contour*

Dalam pengembangan sistem deteksi sampah ini, deteksi kontur menggunakan *OpenCV* memainkan peran kunci. Proses dimulai dengan mengonversi gambar ke skala abu-abu menggunakan `cv2.cvtColor()`, diikuti dengan pengurangan noise melalui `cv2.GaussianBlur()`. Selanjutnya, *thresholding* adaptif diterapkan dengan `cv2.adaptiveThreshold()` untuk menghasilkan gambar biner yang diproses lebih lanjut dengan operasi morfologi melalui `cv2.morphologyEx()`. Kontur pada gambar biner diidentifikasi menggunakan `cv2.findContours()`, yang menentukan batas objek. Kontur yang terdeteksi kemudian dianalisis untuk membentuk kotak pembatas dengan `cv2.boundingRect()`, memungkinkan isolasi dan ekstraksi objek sampah untuk klasifikasi lebih lanjut. Pendekatan ini efektif dalam mengidentifikasi objek dengan berbagai bentuk dan ukuran, relevan dalam deteksi sampah, dan, bila digabungkan dengan model berbasis CNN, memungkinkan sistem untuk mendeteksi serta mengklasifikasikan sampah ke dalam kategori yang sesuai.

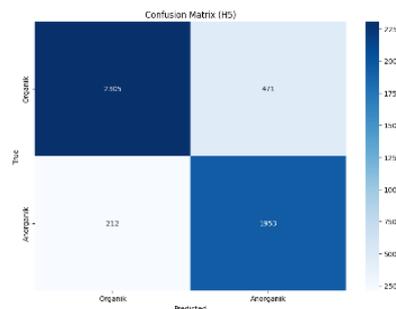
#### 3.5. Hasil dan Pengujian

Hasil deteksi dan pengujian model *deep learning* ini menunjukkan tingkat akurasi yang tinggi dalam mengidentifikasi dan mengklasifikasikan limbah. Proses evaluasi dilakukan dengan menggunakan data uji yang telah dipisahkan sebelumnya, dan hasilnya dibandingkan dengan *ground truth* untuk mengukur kinerja model. Metode ini memastikan bahwa model tidak hanya efektif dalam mengenali pola pada data *training*, tetapi juga mampu mempertahankan performa yang baik pada data yang belum pernah dilihat sebelumnya. Hasil pengujian ini memberikan gambaran tentang kemampuan model dalam aplikasi nyata dan potensinya untuk digunakan dalam sistem deteksi sampah otomatis.



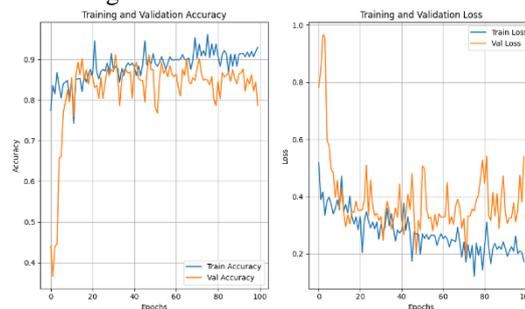
Gambar 4 Deteksi Sampah Organik dan Anorganik

Gambar di atas menunjukkan hasil prediksi model pendeteksian sampah yang mengidentifikasi objek sebagai sampah organik dan sampah daur ulang objek yang terdeteksi adalah gambar pisang dan gambar botol yang menunjukkan bahwa organik terdeteksi dengan kotak berwarna hijau dan anorganik dengan kotak berwarna merah. Menunjukkan hasil yang cukup akurat dalam mendeteksi.



Gambar 5 Confusion Matrix

Pengujian model CNN adalah tahap penting untuk menganalisis performa model, di mana data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Kinerja model dievaluasi menggunakan confusion matrix, yang memberikan detail prediksi benar dan salah, termasuk *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN). Analisis matriks ini membantu memahami kesalahan model dan area yang perlu diperbaiki. Metrik seperti akurasi, presisi, recall, dan skor F1 digunakan untuk mengevaluasi kinerja keseluruhan model dan menentukan langkah-langkah peningkatan klasifikasi sampah organik dan anorganik.



Gambar 6 Grafik Akurasi dan Loss

Evaluasi kinerja model dalam mendeteksi dan mengklasifikasikan limbah dilakukan dengan membagi dataset menjadi data pelatihan dan validasi. Selama beberapa epoch, model dilatih dengan data pelatihan dan diuji pada data validasi untuk mengukur kemampuannya mengenali pola baru. Grafik akurasi dan loss digunakan untuk memantau seberapa baik model mengenali kategori sampah dan seberapa besar tingkat kesalahan prediksi. Analisis grafik ini membantu dalam memahami peningkatan kinerja model, serta mengidentifikasi potensi *overfitting* atau *underfitting*, guna memastikan kemampuan generalisasi yang baik pada data baru. Pada tahap akhir pelatihan, model mencapai akurasi pelatihan 92,97% dan akurasi validasi 78,57%. Meskipun hasil ini menunjukkan bahwa model telah mengenali pola dengan baik, perbedaan yang signifikan antara akurasi pelatihan dan validasi mengindikasikan perlunya peningkatan

dalam hal generalisasi. Secara keseluruhan, model ini menunjukkan potensi yang kuat namun masih dapat dioptimalkan lebih lanjut.

#### 4. Kesimpulan

Penelitian ini menggunakan model *Convolutional Neural Network* (CNN) dengan menggunakan arsitektur AlexNet yang menunjukkan performa yang berbeda dalam mendeteksi sampah organik dan anorganik. Hasil evaluasi kinerja menunjukkan bahwa model mampu mendeteksi sampah organik dengan akurasi sebesar 91,58%, yang menunjukkan kemampuan model yang baik dalam menganalisa sampah jenis ini. Hal ini menunjukkan bahwa fitur-fitur sampah organik berhasil diidentifikasi oleh model. Namun, untuk deteksi sampah anorganik, model hanya mencapai akurasi sebesar 80,57%, yang menunjukkan bahwa model cukup efektif. Pada pelatihan model juga menunjukkan performa yang sangat baik dengan akurasi latih sebesar 92,97% dan validasi sebesar 78,57%. Penelitian ini menunjukkan bahwa model CNN dengan menggunakan arsitektur AlexNet memiliki potensi yang besar dalam mendeteksi jenis sampah dengan menggunakan kontur. Meningkatkan efisiensi dan efektivitas pengelolaan sampah melalui otomatisasi yang akurat dalam mendeteksi jenis sampah menggunakan kontur. Meningkatkan efisiensi dan efektivitas pengelolaan sampah melalui otomatisasi yang akurat.

#### Daftar Pustaka

- [1] SIPSN, "Capaian Kinerja Pengelolaan Sampah," 2023, [Online]. Available: <https://sipsn.menlhk.go.id/sipsn/>
- [2] A. Kahfi, "Overview of Waste Management," *Jurisprudentie: Department of Law, Faculty of Sharia and Law*, vol. 4, no. 1, p. 12, 2017.
- [3] N. Network, "Neural Network의 학습," pp. 1–15, 2018.
- [4] Rima Dias Ramadhani, A. Nur Aziz Thohari, C. Kartiko, A. Junaidi, T. Ginanjar Laksana, and N. Alim Setya Nugraha, "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 312–318, 2021, doi: 10.29207/resti.v5i2.2754.
- [5] Fathoni Dwiatmoko, D. Utami, and Nuari Anisa Sivi, "Klasifikasi Citra Sampah Organik dan Non Organik Menggunakan Algoritma CNN ( Convolutional Neural Network)," *Explore*, vol. 14, no. 1, pp. 1–5, 2024, doi: 10.35200/ex.v14i1.103.
- [6] O. Adedeji and Z. Wang, "Intelligent waste classification system using deep learning convolutional neural network," *Procedia Manuf*, vol. 35, pp. 607–612, 2019, doi: 10.1016/j.promfg.2019.05.086.
- [7] ] Santosa, Mochammad Kevin, Made Hanindia Prami Swari, and Anderas Nugroho Sihananto. "IMPLEMENTASI ARSITEKTUR ALEXNET DAN RESNET34 PADA KLASIFIKASI CITRA PENYAKIT DAUN KENTANG MENGGUNAKAN TRANSFER LEARNING." *JATI (Jurnal Mahasiswa Teknik Informatika)* 7.5 (2023): 3293-3301.
- [8] Sutanty, Ety, and Dina Kusuma Astuti. "Penerapan Model Arsitektur VGG16 Untuk Klasifikasi Jenis Sampah." *Decode: Jurnal Pendidikan Teknologi Informasi* 3.2 (2023): 407-419.
- [9] Stephen, S., Raymond, R., & Santoso, H. (2019). Aplikasi Convolution Neural Network Untuk Mendeteksi Jenis-jenis Sampah. *Explore: Jurnal Sistem Informasi dan Telematika*, 10(2), 331313.
- [10] Riduan, A., Panjaitan, F., Rizal, S., Huda, N., & Purnamasari, S. D. (2024). Detection of Inorganic Waste Using Convolutional Neural Network Method. *Journal of Information Systems and Informatics*, 6(1), 290-300.