

## KLASIFIKASI BAHAN *BIODEGRADABLE* DAN *NON-BIODEGRADABLE* MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK (CNN)*

Muhammad Abdul Latief<sup>1</sup>, Muhammad Rasikh Azfa Riyyasy<sup>2</sup>, Fadilla Zundina Ulya<sup>3</sup>, Popy Laras Puspita<sup>4</sup>, Gavrilla Claudia<sup>5</sup>, Luthfi Rakan Nabila<sup>6</sup>

Prodi Sains Data, Fakultas Informatika, Institut Teknologi Telkom Purwokerto<sup>1,2,3,4,5,6</sup>  
21110002@ittelkom-pwt.ac.id<sup>1</sup>, 21110005@ittelkom-pwt.ac.id<sup>2</sup>, 21110001@ittelkom-pwt.ac.id<sup>3</sup>,  
21110003@ittelkom-pwt.ac.id<sup>4</sup>, 21110004@ittelkom-pwt.ac.id<sup>5</sup>, 20110010@ittelkom-pwt.ac.id<sup>6</sup>

*Submitted July 18, 2023; Revised March 31, 2024; Accepted April 2, 2024*

### Abstrak

*Deep Learning* adalah sebuah bidang keilmuan baru dalam bidang *Machine Learning* yang akhir-akhir ini berkembang. *Deep Learning* memiliki kemampuan yang sangat baik dalam visi komputer. Salah satunya kegunaannya adalah pada kasus klasifikasi objek pada bahan *biodegradable* dan *non-biodegradable*. Dengan mengimplementasikan metode *CNN* pada kasus ini dapat mengklasifikasikan sampah *biodegradable* dan *non-biodegradable* secara tepat dan efisien. Penelitian ini menggunakan data citra bahan *biodegradable* dan *non-biodegradable* yang bersumber dari *Kaggle*. Tahapan pada penelitian ini terdiri dari enam tahap. Tahap pertama ialah mengambil dataset. Tahap kedua merupakan tahap *preprocessing* dengan melakukan *rescaling* gambar. Tahap ketiga adalah membuat model *CNN*. Tahap keempat ialah *training* model untuk mendapatkan akurasi lebih tinggi. Tahap kelima merupakan evaluasi model dan yang terakhir adalah menguji model. Dari uji coba klasifikasi menggunakan metode *CNN* ini mendapatkan akurasi 93%. Sehingga dapat disimpulkan bahwa metode *CNN* yang digunakan pada paper ini mampu melakukan klasifikasi dengan baik.

**Kata Kunci :** Sampah, *biodegradable*, *non-biodegradable*, *CNN*, *deep learning*

### Abstract

*Deep Learning* is a new scientific field in the field of *Machine Learning* which has recently developed. *Deep Learning* has excellent capabilities in computer vision. One of its uses is in the case of classifying objects into *biodegradable* and *non-biodegradable* materials. By implementing the *CNN* method in this case, it is possible to classify *biodegradable* and *non-biodegradable* waste appropriately and efficiently. This study uses image data of *biodegradable* and *non-biodegradable* materials sourced from *Kaggle*. The stages in this study consist of six stages. The first stage is to retrieve the dataset. The second stage is the *preprocessing* stage by *rescaling* the image. The third stage is to create a *CNN* model. The fourth stage is model *training* to get higher accuracy. The fifth stage is model evaluation and the last is testing the model. From the classification test using the *CNN* method, an accuracy of 93% is obtained. So it can be concluded that the *CNN* method used in this paper is capable of performing a good classification.

**Keywords :** Waste, *biodegradable*, *non-biodegradable*, *CNN*, *deep learning*

## 1. PENDAHULUAN

Saat ini, persoalan sampah menjadi salah satu tantangan global yang berkaitan erat dengan keberlanjutan lingkungan dan kesehatan manusia [1]. Pertumbuhan populasi yang pesat dan gaya hidup konsumtif berbanding lurus dengan produksi sampah diseluruh dunia [2].

Sayangnya, manusia belum mampu mengolahnya dengan efektif, sehingga menimbulkan dampak negatif bagi lingkungan dan ekosistem kehidupan [3].

Pemilahan sampah merupakan salah satu komponen kunci dalam pengelolaan sampah yang efektif dan berkelanjutan [4]. Pengelompokan sampah berdasarkan sifat

*biodegradable* dan *non-biodegradable* mempunyai peran yang signifikan dalam konteks ini. Sampah *biodegradable* merupakan jenis sampah yang dapat terurai alami oleh mikroorganisme, seperti daun dan sisa makanan. Namun sebaliknya, sampah *non-biodegradable* merupakan jenis sampah yang tidak dapat terurai oleh bakteri maupun mikroorganisme, seperti plastik, logam, dan kaca [5].

Perbedaan sifat tersebut membuat keduanya harus dikelompokkan agar dapat dikelola dengan cara yang sesuai. Selain itu, pengelompokan sampah yang tepat juga dapat mengurangi dampak negatifnya terhadap lingkungan dan memaksimalkan potensi daur ulang [6]. Dalam upaya tersebut, perlu dilakukan klasifikasi untuk mengelompokkan sampah berdasarkan sifat *biodegradable* dan *non-biodegradable*.

Teknologi yang terus berkembang pesat, mendukung kinerja manusia menjadi lebih cepat, tepat, dan efisien. Salah satu implementasinya yaitu dengan adanya sistem kecerdasan buatan (*artificial intelligence*) [7]. Kecerdasan buatan mampu meniru dan mengadopsi kecerdasan manusia untuk meningkatkan performa komputer maupun perangkat lunak dalam mengolah informasi. Perkembangannya yang signifikan membuat algoritma didalamnya sudah mampu digunakan dalam pengenalan citra atau gambar [8].

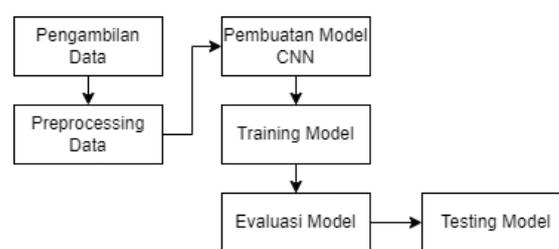
Pengenalan citra dapat dilakukan dengan metode *deep learning* dan *computer vision*. Salah satu algoritma *deep learning* yang umum yang digunakan dalam pengenalan citra yaitu *Convolutional Neural Network (CNN)* [9]. *CNN* merupakan sebuah metode yang menerapkan operasi matematika untuk menggantikan perhitungan kompleks dalam setiap lapisan. Metode ini digunakan untuk mengurangi beban perhitungan dalam operasi multiplikasi matriks di dalam layer [10].

Penelitian terdahulu yang relevan dengan pengenalan citra telah banyak dilakukan di berbagai bidang. Pada bidang kesehatan, algoritma *CNN* dilakukan untuk mengklasifikasikan penyakit mata dengan arsitektur *Alexnet* [11]. Sementara itu, penelitian yang membahas tentang klasifikasi *biodegradable* dan *non-biodegradable* dilakukan oleh Atik menggunakan algoritma *CNN* [12]. Akurasi tertinggi didapatkan ketika klasifikasi dilakukan menggunakan model *ShuffleNet CNN*.

Berdasarkan uraian yang telah dipaparkan, penelitian ini dilakukan untuk mengklasifikasikan sampah *biodegradable* dan *non-biodegradable* berbasis citra menggunakan algoritma *CNN*. Algoritma *CNN* dipilih karena dapat diterapkan pada citra resolusi tinggi yang berdistribusi non parametrik, mengekstraksi pola secara otomatis, serta mampu menerima dan memproses banyak input dalam waktu yang bersamaan [13].

## 2. METODE PENELITIAN

Penelitian ini dibagi menjadi beberapa langkah atau proses yang dapat dilihat dari gambar berikut :



Sumber: Dokumen Penulis, 2023

Gambar 1. Diagram Alir Penelitian

### Pengambilan Data

Pada tahap pertama, peneliti mengambil data pada situs [www.kaggle.com](http://www.kaggle.com). Kaggle adalah web penyedia dataset yang biasa digunakan untuk keperluan *data science* [14]. Data yang diambil adalah data gambar yang memiliki 2 kelas yaitu bahan yang bisa

terurai secara alami dan bahan yang tidak bisa terurai secara alami.

### ***Preprocessing Data***

Tahap ini merupakan tahapan selanjutnya setelah data didapatkan. *Preprocessing* dapat menghindari permasalahan yang dapat mengganggu hasil klasifikasi model [11]. *Preprocessing* yang diterapkan adalah menghilangkan gambar yang tidak valid dan normalisasi data dengan cara *rescaling* gambar.

### ***Convolutional Neural Network (CNN)***

*Convolutional Neural Network* merupakan salah satu algoritma yang termasuk pada bidang *Deep Learning*. *CNN* atau *Convolutional Neural Network* adalah variasi *neural network* yang memiliki bobot dan lapisan terselubung yang kemudian disusun menjadi sebuah arsitektur. Konsep utama dari *CNN* terletak pada *convolution*, yang mana akan mengekstraksi fitur dari citra untuk membentuk pola yang mudah dalam klasifikasi [15]. *CNN* memiliki tingkat akurasi yang cukup tinggi karena cara kerjanya menyerupai pengenalan citra yang dilakukan oleh manusia [16].

### ***Training Model***

*Training model* adalah tahapan dimana melatih model berdasarkan data untuk mendapatkan akurasi lebih tinggi dari klasifikasi yang dilakukan. Dari training nantinya dapat diketahui akurasi *training* dan *loss* yang didapatkan. *Training* dilakukan menggunakan data yang sudah dipisah pada tahap *preprocessing*.

### ***Evaluasi Model***

Evaluasi bertujuan untuk menilai model berdasarkan prediksinya dengan data test. Evaluasi dilakukan terhadap model *convolutional neural network* yang sudah dilatih sebelumnya.

### ***Testing Model***

Tahap ini merupakan tahap terakhir dalam penelitian. Model yang sudah dievaluasi

kemudian diuji menggunakan gambar yang berbeda dari data training dan evaluasi. *Testing* dilakukan dengan cara menginputkan gambar *biodegradable* atau *non-biodegradable*, setelah itu model akan mengklasifikasikan gambar tersebut dan memberikan output berupa label.

## **3. HASIL DAN PEMBAHASAN**

### **Pengambilan Data**

Dataset yang digunakan pada penelitian ini berasal dari *Kaggle* milik Rayhan Zamzamy. Data tersebut terdiri dari 239.690 *data training* dan 16.726 *data testing*. Penelitian ini menjelaskan klasifikasi perbedaan sampah *biodegradable* dan *non-biodegradable*. Pada Gambar 2 dan 3 disajikan contoh gambar *non-biodegradable* dan *biodegradable* dalam dataset:



Sumber: Kaggle Dataset Non and Biodegradable Material

**Gambar 2. Non-biodegradable**



Sumber: Kaggle Dataset Non and Biodegradable Material

**Gambar 3. Biodegradable**

### Preprocessing Data

Tahapan *preprocessing* yang dilakukan pada penelitian ini adalah penghapusan data gambar yang tidak valid dan normalisasi data. Data gambar dikatakan valid apabila memiliki ekstensi file ('jpeg', 'jpg', 'bmp', 'png'). Setelah pemilihan data yang valid, selanjutnya program akan dilakukan normalisasi dengan cara melakukan *rescale* gambar yang akan menghasilkan dataset baru dengan skala yang sama antara 0 sampai 1. Dataset tersebut digunakan untuk melatih dan menguji model *CNN*. Banyaknya data yang akan di *split* adalah dengan membagi dataset menjadi 70% untuk *training set*, 20% untuk *validation set*, dan 10% untuk *test set* dari total dataset.

### Pembuatan Model CNN

Model yang digunakan dalam penelitian ini adalah *Convolution Neural Network (CNN)*. Jumlah layer dalam penelitian ini sebanyak 5 layer ditambah dengan layer drop out untuk meminimalisir *overfitting* dan *optimizer* yang digunakan adalah *Adam* dengan nilai learning rate sebesar 0.0001. Model yang diterapkan dapat dilihat pada Gambar 4.

Layer (type)	Output Shape	Param #
conv2d_10 (Conv2D)	(None, 254, 254, 64)	1792
max_pooling2d_10 (MaxPoolin g2D)	(None, 127, 127, 64)	0
conv2d_11 (Conv2D)	(None, 125, 125, 32)	18464
max_pooling2d_11 (MaxPoolin g2D)	(None, 62, 62, 32)	0
conv2d_12 (Conv2D)	(None, 60, 60, 16)	4624
max_pooling2d_12 (MaxPoolin g2D)	(None, 30, 30, 16)	0
conv2d_13 (Conv2D)	(None, 28, 28, 8)	1168
max_pooling2d_13 (MaxPoolin g2D)	(None, 14, 14, 8)	0
conv2d_14 (Conv2D)	(None, 12, 12, 16)	1168
max_pooling2d_14 (MaxPoolin g2D)	(None, 6, 6, 16)	0
flatten_2 (Flatten)	(None, 576)	0
dense_4 (Dense)	(None, 256)	147712
dropout_2 (Dropout)	(None, 256)	0
dense_5 (Dense)	(None, 1)	257

-----  
 Total params: 175,177  
 Trainable params: 175,177  
 Non-trainable params: 0

Sumber: Dokumen Penulis, 2023

**Gambar 4. Model yang Diterapkan**

Layer pertama menambahkan lapisan konvolusi dengan 64 filter dan dimensi input pertama untuk model ini (256,256) kemudian diperoleh hasil *Max Pooling* pada layer pertama (127,127). Pada layer kedua menambahkan lapisan konvolusi dengan 32 filter dengan dimensi input kedua adalah (125,125) kemudian diperoleh hasil *Max Pooling* pada layer kedua adalah (62,62). Pada layer ketiga menambahkan lapisan konvolusi dengan 16 filter dengan dimensi input ketiga untuk model ini (60,60) kemudian diperoleh hasil *Max Pooling* pada layer ketiga (30,30). Selanjutnya untuk layer keempat menambahkan lapisan konvolusi dengan 8 filter dengan dimensi input keempat untuk model ini adalah (28,28) kemudian diperoleh hasil *Max Pooling* pada layer keempat (14,14). Layer kelima menambahkan lapisan konvolusi dengan 16 filter dengan dimensi input kelima untuk model ini (12,12) kemudian diperoleh hasil *Max Pooling* pada layer kelima (6,6).

Selanjutnya dilanjutkan dengan lapisan *Flatten*, yang mengubah peta fitur menjadi vektor satu dimensi. Kemudian, ditambahkan lapisan *Dense* dengan 256 neuron. Lapisan *Dropout* diterapkan dengan *dropout rate* 0.25, yang secara acak menonaktifkan 25% neuron dalam lapisan sebelumnya untuk mencegah *overfitting*. Terakhir, lapisan *Dense* terakhir dengan 1 neuron dan fungsi aktivasi sigmoid digunakan untuk output klasifikasi biner, di mana nilai output antara 0 dan 1.

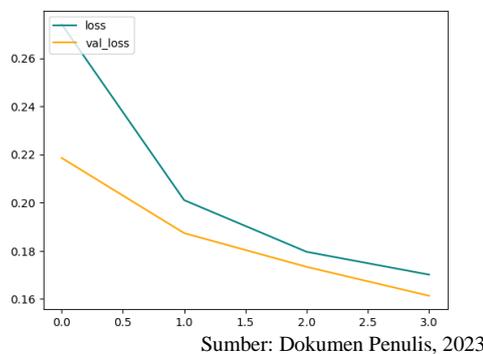
### Training Model

Pada penelitian ini digunakan 70% *data training* dari total dataset, dan *training model* dilakukan sebanyak 4 iterasi. Selama pelatihan model diperoleh nilai *loss* adalah 0.2688 artinya model dalam memprediksi label yang benar untuk *data train*. Semakin rendah nilai *loss*, semakin baik performa model dalam mempelajari pola dari *data train*. Nilai akurasi adalah 0.8912 artinya 89% *data train* yang diklasifikasikan

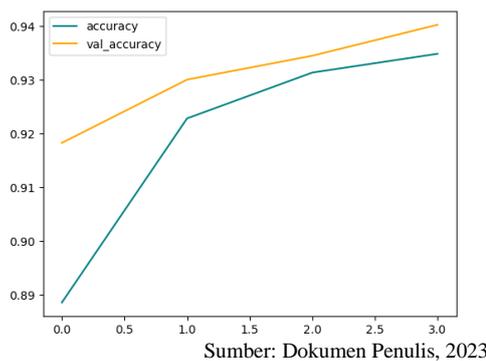
dengan benar oleh model. Nilai validasi *loss*, adalah 0.2106 artinya model dalam memprediksi label yang benar pada data val bagus. Selanjutnya nilai akurasi validasi adalah 0.9209 artinya model dapat mengenali dan mengklasifikasikan data val yang belum pernah dilihat sebelumnya dengan baik.

### Evaluasi Model

Tahapan selanjutnya adalah mengevaluasi model dengan metrik evaluasi dalam mengetahui performa model pada data pengujian.



Gambar 5. Grafik Loss



Gambar 6. Grafik Akurasi

Berdasarkan Gambar 5 dan 6 dapat dijelaskan klasifikasi menggunakan *Convolutional Neural Network (CNN)* menghasilkan akurasi 0.93907124 artinya 93% model yang digunakan secara keseluruhan dalam mengklasifikasikan data dapat berjalan dengan benar. Selain itu,

diperoleh presisi sebesar 0.9424907 artinya 94% model benar dalam mengidentifikasi kelas positif dari semua prediksi yang dilabeli sebagai kelas positif, dan diperoleh *recall* 0.93714005 artinya 93% model berhasil menemukan semua sampel positif yang benar.

### Testing Model

*Testing* pada model dilakukan untuk menguji performa model dengan menginputkan contoh data yang ingin dimodelkan untuk mendapatkan prediksi dari model. Berikut adalah beberapa gambar yang diprediksi.



Sumber: Dokumen Penulis, 2023

Gambar 7. Testing dengan Non-biodegradable



Sumber: Dokumen Penulis, 2023

Gambar 8. Testing dengan Biodegradable

Berdasarkan Gambar 7 dan 8 menunjukkan gambar sebagai data yang digunakan untuk

mengetahui klasifikasinya, diperoleh prediksi dari model bahwa data gambar (a) merupakan *non-biodegradable* dan data gambar (b) merupakan *biodegradable*. Artinya klasifikasi *non-biodegradable* dan *biodegradable* menggunakan *CNN* dapat menghasilkan prediksi yang sangat tepat.

#### 4. SIMPULAN

Berdasarkan hasil dan pembahasan di atas, dapat disimpulkan bahwa penelitian ini berhasil mengimplementasikan *Convolutional Neural Network (CNN)* untuk klasifikasi sampah menjadi kategori *biodegradable* dan *non-biodegradable* dengan performa yang baik. Model *CNN* menghasilkan akurasi sebesar 0.93907124 yang mengindikasikan bahwa 93% model yang digunakan secara keseluruhan dalam mengklasifikasikan data dapat berjalan dengan benar, presisi sebesar 0.9424907 yang mengindikasikan bahwa 94% model benar dalam mengidentifikasi kelas positif dari semua prediksi yang dilabeli sebagai kelas positif, dan *recall* sebesar 0.93714005 yang mengindikasikan bahwa 93% model berhasil menemukan semua sampel positif yang benar.

Secara keseluruhan, penelitian ini menunjukkan bahwa penggunaan model *CNN* untuk klasifikasi sampah *biodegradable* dan *non-biodegradable* menghasilkan prediksi yang sangat baik. Model *CNN* dapat digunakan untuk mengenali dan memilah sampah dengan tepat, sehingga dapat membantu dalam upaya pengelolaan sampah yang lebih efisien dan berkelanjutan.

#### DAFTAR PUSTAKA

- [1] M. Z. Hakim, "Pengelolaan dan Pengendalian Sampah Plastik Berwawasan Lingkungan," *Amanna Gappa*, vol. 27, no. 2, hal. 111–121, 2019.
- [2] M. Salim *et al.*, "Membentuk kesadaran dampak sampah melalui pemahaman gaya hidup minim sampah," *J. Community Dev. Soc.*, vol. 2, no. 2, hal. 119–127, 2020.
- [3] M. Z. Elamin *et al.*, "Analisis Pengelolaan Sampah pada Masyarakat Desa Disanah Kecamatan Sreseh Kabupaten Sampang," *J. Kesehat. Lingkung.*, vol. 10, no. 4, hal. 368, 2018.
- [4] N. M. Armadi, "Peran Serta Masyarakat Dalam Pengelolaan Sampah Sebagai Kunci Keberhasilan Dalam Mengelola Sampah," *J. Ilmu Sos. dan Ilmu Polit.*, vol. 35, no. 1, hal. 9–24, 2021.
- [5] S. Purtnavita, "Pembuatan Plastik Biodegradable dari Pati Aren dengan Penambahan Aloe Vera," *Inov. Tek. Kim.*, vol. 3, no. 2, hal. 31–35, 2018.
- [6] S. Pramadita, "Potensi Daur Ulang Sampah Melalui Identifikasi Jenis Dan Karakteristik Sampah Di Panti Asuhan Dan Pesantren Darul Khairat," *J. Teknol. Lingkung. Lahan Basah*, vol. 9, no. 2, hal. 082, 2021.
- [7] K. R. Ririh, N. Laili, A. Wicaksono, dan S. Tsurayya, "Studi Komparasi dan Analisis Swot Pada Implementasi Kecerdasan Buatan (Artificial Intelligence) di Indonesia," *J. Tek. Ind.*, vol. 15, no. 2, hal. 122–133, 2020.
- [8] A. A. Himawan *et al.*, "Rancang Bangun Ai Virtual Mouse Berbasis Pengolahan Citra," in *e-Proceeding of Applied Science*, 2023, vol. 9, no. 1, hal. 232–246.
- [9] F. R. Ummah dan D. T. Utari, "Covid-19 and Tuberculosis Detection in X-Ray of Lung Images with Deep Convolutional Neural Network," *Int. J. Adv. Soft Comput. its Appl.*, vol. 14, no. 3, hal. 1–16, 2022.
- [10] S. Frangky Handono, F. Tri Anggraeny, dan B. Rahmat, "Implementasi Convolutional Neural Network (CNN) Untuk Deteksi

- Retinopati Diabetik,” *J. Inform. dan Sist. Inf.*, vol. 1, no. 1, hal. 669–678, 2020.
- [11] F. N. Cahya, N. Hardi, D. Riana, dan S. Hadiyanti, “Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN),” *Sist. J. Sist. Inf.*, vol. 10, no. 3, hal. 618, 2021.
- [12] I. Atik, “Analysis of Biodegradable and Non-Biodegradable Materials Using Selected Deep Learning Algorithms,” *Int. J. Comput.*, vol. 45, no. 1, hal. 48–59, 2022.
- [13] E. N. Arrofiqoh dan H. Harintaka, “Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi,” *Geomatika*, vol. 24, no. 2, hal. 61, 2018.
- [14] F. S. Pamungkas, B. D. Prasetya, dan I. Kharisudin, “Perbandingan Metode Klasifikasi Supervised Learning pada Data Bank Customers Menggunakan Python,” in *PRISMA, Prosiding Seminar Nasional Matematika*, 2020, vol. 3, hal. 689–694.
- [15] N. Buslim dan R. P. Iswara, “Pengembangan Algoritma Unsupervised Learning Technique Pada Big Data Analysis di Media Sosial sebagai media promosi Online Bagi Masyarakat,” *J. Tek. Inform.*, vol. 12, no. 1, hal. 79–96, 2019.
- [16] F. F. Maulana dan N. Rochmawati, “Klasifikasi Citra Buah Menggunakan Convolutional Neural Network,” *J. Informatics Comput. Sci.*, vol. 1, no. 02, hal. 104–108, 2020.