

---

## ANALISIS PERBANDINGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK DAN ALGORITMA MULTI-LAYER PERCEPTRON NEURAL DALAM KLASIFIKASI CITRA SAMPAH

Kelvin Leonardi Kohsasih<sup>[1]</sup>, Muhammad Dipo Agung Rizky<sup>[2]</sup>, Tasya Fahriyani<sup>[3]</sup>,  
Veronica Wijaya<sup>[4]</sup>, Rika Rosnelly<sup>[5]</sup>

Mahasiswa Program Studi Pascasarjana Ilmu Komputer, Fakultas Teknik dan Ilmu Komputer  
Dosen Program Studi Pascasarjana Ilmu Komputer, Fakultas Teknik dan Ilmu Komputer  
Universitas Potensi Utama, Jl.K.L. Yos Sudarso KM.6,5 No.3A, Tj Mulia, Medan  
e-mail : ceokelvin12@gmail.com<sup>[1]</sup>, dipo.ar@gmail.com<sup>[2]</sup>, tfahriyani@gmail.com<sup>[3]</sup>,  
veronicawijaya86@gmail.com<sup>[4]</sup>, rikarosnelly@gmail.com<sup>[5]</sup>

---

### Abstrak

Menurut laporan bank dunia sampah merupakan salah satu permasalahan yang dihadapi dunia. Image clasification adalah salah satu bidang machine learning yang mampu melakukan klasikasi sampah berdasarkan jenisnya. Salah satu algoritma klasifikasi yang populer dan banyak digunakan adalah algoritma CNN yang merupakan algoritma deep learning. Pada penelitian ini kami akan melakukan analisis perbandingan kinerja algoritma CNN dengan algoritma MLP dalam melakukan klasifikasi jenis sampah. Dari penelitian yang kami lakukan, CNN mendapatkan performa yang lebih baik dimana hasil precision, recall, f1-score, dan accuracy sebesar 0,98 dan model CNN lebih efektif dalam melakukan klasifikasi sampah berdasarkan kelasnya.

**Kata Kunci:** *machine learning, deep learning, image classification, multi-layer perceptron, convolutional neural network*

### Abstract

According to the World Bank report, waste is one of the problems that the world is facing. Image classification is one of the fields of machine learning that is capable of classifying waste based on its type. One of the most widely popular used classifications is the CNN algorithm which is a deep learning algorithm. In this study, we will perform a comparative analysis of the performance of the CNN algorithm with the MLP algorithm in terms of classifying waste types. From the research we did, CNN got a better performance where the results of precision, recall, f1-score, and accuracy were 0.98 and the CNN model was more effective in classifying waste based on its class.

**Keyword:** *machine learning, deep learning, image classification, multi-layer perceptron, convolutional neural network*

### 1. Pendahuluan

sampah merupakan salah satu masalah yang selalu muncul di Negara Indonesia bahkan didunia. Semakin lama semakin meningkat produksi sampah yang dihasilkan seiring dengan bertambahnya penduduk dan konsumsi masyarakat.[1] Bank Dunia melaporkan bahwa hampir 4 miliar ton sampah dihasilkan setiap tahun di seluruh dunia. dan perkotaan saja menyumbang banyak untuk jumlah ini, sampah diprediksi meningkat 70 persen pada tahun 2025[2].

*Image classification* merupakan salah satu bidang *machine learning* yang diminati karena mampu menggantikan kemampuan visual manusia. Dengan menggunakan *image classification* maka komputer dapat mengetahui Jenis sampah Seperti sampah kardus, plastik, kertas, logam dan kaca hanya berdasarkan gambar secara real time. Dengan aplikasi *image classification* dapat membantu dalam pengembangan *self-autonomous machine* atau *Advance Driver Assistance System (ADAS)*[3]

Machine Learning dan teknik Image processing yang berbeda telah diusulkan dalam literatur untuk klasifikasi gambar dan objek yang berbeda[4]. Salah satu yang paling sering digunakan dalam metode pembelajaran untuk klasifikasi citra adalah *Convolutional Neural Network (CNN)* yang berkinerja baik dalam mengklasifikasikan kumpulan data gambar serta untuk pengenalan gambar waktu nyata Aplikasi[4][5][6]. Menurut Azis, F. A., Suhaimi, H., & Abas, E yang melakukan penelitian klasifikasi sampah daur ulang dengan menggunakan algoritma CNN untuk melakukan dengan ekstraksi beberapa fitur dari kumpulan data gambar, mengelompokkan kumpulan data dan kemudian, menggunakan informasi untuk mengklasifikasikan gambar menjadi 6 kelas yaitu karton, kaca, logam, kertas, plastik dan sampah lainnya[4].

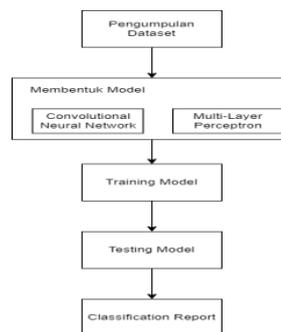
Selanjutnya penelitian terdahulu mengenai *image classification* yaitu [7] telah melakukan perbandingan terhadap algoritma CNN dan *Support Vector Machine (SVM)* untuk klasifikasi sampah. Proses klasifikasi dilakukan dengan memperkecil gambar input yang berukuran 256 x 256 menjadi 32 x 32. Untuk arsitektur CNN mereka, mereka menggunakan model AlexNet. Setiap algoritma membuat pengklasifikasi berbeda yang membagi

sampah menjadi tiga kategori: plastik, kertas, dan logam. Akurasi klasifikasi SVM adalah 94,8% sedangkan akurasi klasifikasi CNN adalah 83%. Menurut Maeda-Gutiérrez V melakukan penelitian untuk membandingkan kinerja AlexNet, GoogleNet, Inception V3, ResNet 18, dan ResNet 50 dengan perbedaan metrik kinerja. di mana GoogleNet model dengan 22 lapisan dapat mencapai 99,72% dan menunjukkan keefektifan mengklasifikasikan dengan kombinasi CNN dan penyesuaian fine-tuning. Di sisi lain, Inception V3 memperoleh kinerja terendah dibandingkan arsitektur yang lain[8].

berdasarkan beberapa penelitian terdahulu. Tidak ditemukan penelitian yang membandingkan kinerja algoritma *convolutional neural network* dengan algoritma machine learning tradisional seperti *Multi-Layer perceptron*. Pada penelitian ini kami akan melakukan analisis perbandingan algoritma CNN dengan algoritma machine learning tradisional yaitu *Multi-layer Perceptron*, untuk melihat perbandingan performansi dan waktu eksekusi antara kedua algoritma tersebut.

## 2. Metode Penelitian

Metode penelitian meliputi pengumpulan data set, pelatihan model klasifikasi, melakukan pelatihan model, pengujian model dan penulisan laporan klasifikasi. Flowchart metodologi pada penelitian ini dapat dilihat pada gambar 1.



**Gambar** Flowchart metode penelitian

### Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah citra sampah yang diperoleh dari *Garbage Classification* pada repositori kaggle. Terdapat enam kelas sampah, yaitu cardboard, glass, metal, paper, plastic, dan trash [9]. Jumlah dataset dari setiap kelas sampah dapat dilihat pada Tabel 1. Sample gambar dataset pada masing-masing kelas dapat dilihat pada gambar 2. Dataset yang digunakan diubah ukurannya menjadi 150x150 sebelum dilakukan proses pelatihan dan pengujian

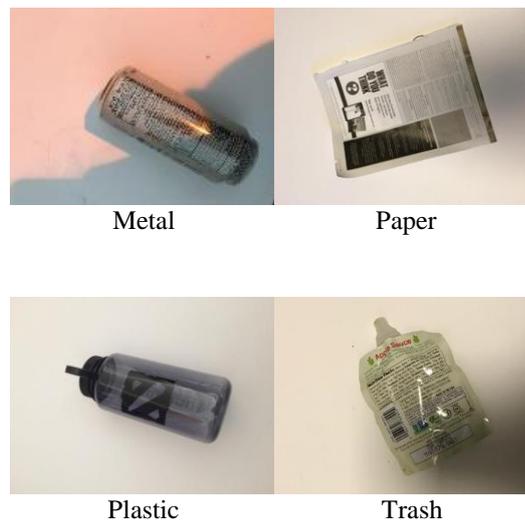
Kelas	Jumlah
Cardboard	403
Glass	501
Metal	410
Paper	594
Plastic	482
Trash	137

**Tabel 1** Detail jumlah dataset



Cardboard

Glass



**Gambar 2** Gambar Dataset Sampah

### Pembentukan Model Klasifikasi

Pada tahap pembentukan model klasifikasi, Kami membagi data masing-masing kelas menjadi 60% data training dan 40% data testing. Setelah itu kami melakukan *preprocessing* gambar dan latih penggunaan model pustaka tensorflow dari bahasa pemrograman Python. Dalam penelitian ini, *preprocessing citra* yang kami digunakan adalah augmentasi. Augmentasi gambar memperkaya data untuk membuat model mengetahui sedikit bentuk yang berbeda dengan gambar asal. Ini mirip dengan data pelatihan dari *multi-object* dengan bentuk yang berbeda[10]. setiap algoritma akan diuji dengan beberapa parameter. Tujuannya adalah untuk menentukan pengaruh parameter terhadap kinerja hasil.

Pada algoritma *multi-layer perceptron*, parameter yang diuji meliputi jumlah epoch, jenis fungsi aktivasi, dan jumlah lapisan dense [11]. Struktur parameter yang digunakan pada algoritma multi-layer perceptron dapat dilihat pada gambar 3.

Layer (type)	Output Shape	Param #
flatten (Flatten)	(None, 67500)	0
dense (Dense)	(None, 128)	8640128
dense_1 (Dense)	(None, 128)	16512
dense_2 (Dense)	(None, 6)	774
-----		
Total params: 8,657,414		
Trainable params: 8,657,414		
Non-trainable params: 0		

**Gambar 3** Parameter Algoritma MLP

Pada algoritma convolutional neural network, parameter yang diuji meliputi jumlah epoch, jenis konvolusi, jenis fungsi aktivasi, dan jumlah lapisan dense. struktur parameter yang digunakan pada algoritma CNN dapat dilihat pada gambar 4. Arsitektur CNN yang digunakan adalah LeNet[12].

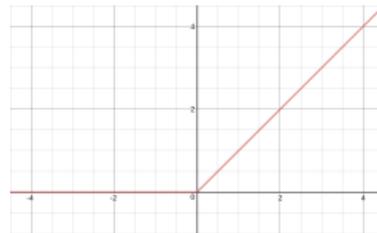
Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 148, 148, 32)	896
max_pooling2d (MaxPooling2D)	(None, 74, 74, 32)	0
conv2d_1 (Conv2D)	(None, 72, 72, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 36, 36, 64)	0
conv2d_2 (Conv2D)	(None, 34, 34, 128)	73856
max_pooling2d_2 (MaxPooling2D)	(None, 17, 17, 128)	0
conv2d_3 (Conv2D)	(None, 15, 15, 128)	147584
max_pooling2d_3 (MaxPooling2D)	(None, 7, 7, 128)	0
flatten (Flatten)	(None, 6272)	0
dense (Dense)	(None, 512)	3211776
dense_1 (Dense)	(None, 6)	3078
-----		
Total params: 3,455,686		
Trainable params: 3,455,686		
Non-trainable params: 0		

Gambar 4 Parameter algoritma CNN

Fungsi aktivasi yang digunakan dalam lapisan dense layer pada model MLP dan lapisan convolutional dan dense layer pertama pada model CNN adalah ReLU (*Rectified Linear Unit*). ReLU adalah fungsi aktivasi yang diperkenalkan oleh Richard HR Hahnloser yang memiliki dasar matematis dan biologis yang kuat. Pada tahun 2011, terbukti lebih meningkatkan pelatihan jaringan saraf dalam. Ia bekerja dengan nilai ambang pada 0 yang diberikan dalam persamaan (1), dalam istilah awam ia mengembalikan 0 ketika  $x < 0$  dan sebaliknya, ini menghasilkan fungsi linier ketika  $x \geq 0$  [13].

$$f(x) = \max(0, x)$$

Representasi visual fungsi aktivasi ReLU dapat dilihat pada gambar 5 (1)



Gambar 5 Visualisasi Rectified Linear Unit

Pada Lapisan output fungsi aktivasi yang digunakan adalah fungsi aktivasi softmax hal ini dikarenakan jumlah kelas pada klasifikasi berjumlah 6. rumus fungsi aktivasi softmax ditunjukkan pada persamaan (2).

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \tag{2}$$

**Pelatihan Model**

Pada tahapan ini, kami melakukan proses pelatihan pada model yang dilatih. Pelatihan dilakukan dengan menggunakan data pelatihan dari dataset. Dari setiap sesi pelatihan, dilakukan pengujian menggunakan metode *cross validation*.

Model CNN dan MLP yang digunakan selama pelatihan ini juga menggunakan langkah-langkah data augmentasi untuk menghindari *overfitting*. Data augmentation menggunakan pustaka yang disediakan oleh *keras*. Peningkatan data yang digunakan dapat dilihat pada Tabel 2.

Parameter	Value
Rescale	1./255
Rotation	20
Range	
Horizontal	True
Flip	
Shear	0.2
Range	

Fill Mode nearest

**Tabel 2** Data Augmentation model**Pengujian Model**

Pada tahapan testing kami melakukan pengujian terhadap model yang telah dilatih. Proses pengujian dilakukan dengan menggunakan data testing dari dataset. Selanjutnya kami melakukan perbandingan performa dari setiap *cross validation*. Hal ini bertujuan untuk melihat apakah model yang telah dilatih memiliki performa yang bagus atau buruk.

**Laporan Klasifikasi**

Pada tahap ini, kami melakukan penyusunan laporan hasil pengujian klasifikasi pada model MLP dan CNN yang akan dihitung dalam bentuk *Confusion Matrix*. Dengan parameter pengujian hasil yang berupa *Accuracy*, *Precision*, *Recall*, dan *F1 Score* untuk mengukur kinerja suatu model yang memiliki hasil terbaik dari metode yang telah ditentukan. rumus perhitungan *Accuracy*, *Precision*, dan *Recall* di tunjukkan pada persamaan (3)(4)(5) berturut turut[14].

$$Akurasi = \frac{\sum_{i=1}^I \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i}}{I} * 100\% \quad (3)$$

$$Presisi = \frac{\sum_{i=1}^I TP_i}{\sum_{i=1}^I (FP_i + TP_i)} * 100\% \quad (4)$$

$$Recall = \frac{\sum_{i=1}^I TP_i}{\sum_{i=1}^I (TP_i + FN_i)} * 100\% \quad (5)$$

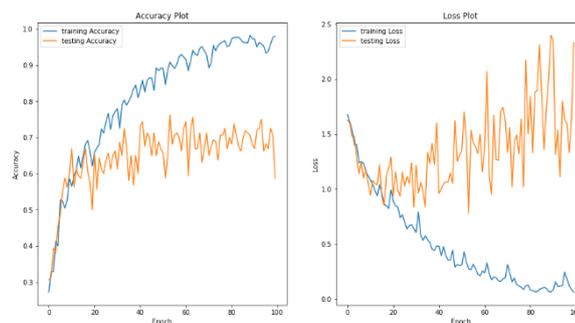
dimana:

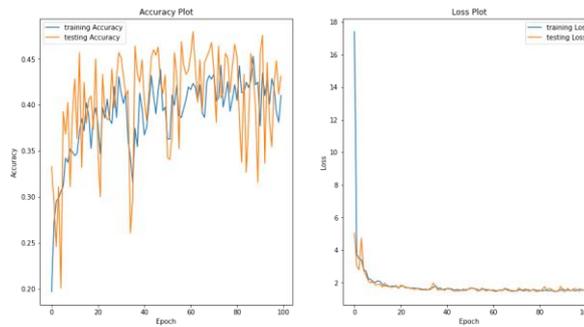
- $TP_i$  = Jumlah data positif yang benar pada kelas  $i$ .
- $TN_i$  = Jumlah data negatif yang benar pada kelas  $i$ .
- $FN_i$  = Jumlah data negatif yang salah pada kelas  $i$ .
- $FP_i$  = jumlah data positif yang salah pada kelas  $i$ .
- $i$  = jumlah kelas.

**3. Hasil dan Pembahasan**

Total gambar yang kami peroleh dari dataset Kaggle adalah 2527 gambar yang terdiri dari *cardboard*, *glass*, *metal*, *paper*, *plastic*, dan *trash*. Kemudian kami membagi data menjadi data pelatihan dan memvalidasi data. Untuk data pelatihan kami memiliki 1514 gambar dan untuk memvalidasi data kami memiliki 1013 gambar.

Dalam pemrosesan gambar, kami melakukan *Image Augmentasi* dengan rotasi 20 derajat, rescale size, zoom dan balikkan gambar ke horizontal. Augmentasi memperkaya data dan membuat model melatih data menjadi banyak sudut pandang. Selanjutnya dalam melakukan pengujian terhadap hasil training, kami menggunakan nilai epoch 100 pada masing masing model. Berikut adalah grafik yang menunjukkan hasilnya.

**Gambar 6** Grafik Model CNN



**Gambar 7** Grafik Model MLP

Perbandingan performa antara algoritma *convolutional neural network* and algoritma *multi-layer perceptron* dapat dilihat pada tabel 3.

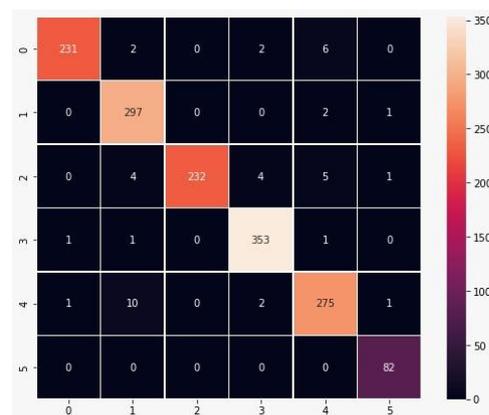
Method	Class	Precision	Recall	f1-score	Accuracy
CNN	Paper	1,00	0,96	0,98	0,98
	Plastic	0,97	0,98	0,98	
	Glass	1,00	0,94	0,97	
	Metal	0,98	0,99	0,99	
	Trash	0,94	0,98	0,96	
	Cardboard	0,98	1,00	0,99	
MLP	Paper	0,53	0,65	0,58	0,43
	Plastic	0,30	0,06	0,10	
	Glass	0,27	0,59	0,37	
	Metal	0,56	0,61	0,59	
	Trash	0,50	0,39	0,44	
	Cardboard	0,00	0,00	0,00	

**Tabel 3** Perbandingan Model CNN dan MLP

Berdasarkan tabel 3 Model yang menggunakan algoritma CNN mendapatkan hasil yang lebih baik yaitu 98% dibandingkan model algoritma MLP yang hanya mendapatkan akurasi 43%. Selain itu performa yang dihasilkan model CNN cukup signifikan jika dibandingkan dengan MLP. Adapun *Confusion Matrix* dari kedua algoritma dapat dilihat pada gambar 8 dan 9.



**Gambar 8** Confusion Matrix Model MLP



### Gambar 9 Confusion Matrix Model CNN

#### 4. Kesimpulan

Berdasarkan hasil pengujian yang telah kami lakukan pada penelitian ini, Model yang dibangun dengan menggunakan algoritma CNN memiliki performa yang lebih baik yaitu dengan tingkat accuracy, precision, recall dan f1-score sebesar 0.98%. Sedangkan model yang dibangun dengan menggunakan algoritma MLP hanya mendapatkan accuracy sebesar 0.43, precision 0.41, recall 0.43 dan f1-score sebesar 0.39. Namun pada proses pelatihan dan pengujian model yang dibangun menggunakan algoritma CNN membutuhkan waktu yang lebih lama dibandingkan algoritma MLP. Selain itu model yang dibangun menggunakan algoritma CNN lebih efektif untuk digunakan dalam klasifikasi gambar sampah yang terdiri dari sampah kardus, kaca, logam, plastik, kertas dan sampah lainnya.

Rekomendasi untuk penelitian selanjutnya adalah melakukan peningkatan kinerja algoritma MLP yang mempunyai hasil yang kurang memuaskan, selain itu pada penelitian selanjutnya dapat menggunakan dataset yang berbeda dan dapat membandingkan kinerja algoritma CNN dengan algoritma lain dalam proses klasifikasi.

#### 5. Daftar Pustaka

- [1] L. Leonardo, Y. Yohannes, and E. Hartati, "Klasifikasi Sampah Daur Ulang Menggunakan Support Vector Machine Dengan Fitur Local Binary Pattern," *Jurnal Algoritme*, vol. 1, no. 1, pp. 78–90, Oct. 2020, doi: 10.35957/algoritme.v1i1.440.
- [2] O. Adedeji and Z. Wang, "Intelligent waste classification system using deep learning convolutional neural network," in *Procedia Manufacturing*, 2019, vol. 35, pp. 607–612. doi: 10.1016/j.promfg.2019.05.086.
- [3] L.-W. Kang, K.-L. Chou, and R.-H. Fu, "Deep Learning-Based Weather Image Recognition," in *2018 International Symposium on Computer, Consumer and Control (IS3C)*, Dec. 2018, pp. 384–387. doi: 10.1109/IS3C.2018.00103.
- [4] F. A. Azis, H. Suhaimi, and E. Abas, "Waste Classification using Convolutional Neural Network," in *PervasiveHealth: Pervasive Computing Technologies for Healthcare*, Aug. 2020, pp. 9–13. doi: 10.1145/3417473.3417474.
- [5] K. Chauhan and S. Ram, "Image Classification with Deep Learning and Comparison between Different Convolutional Neural Network Structures using Tensorflow and Keras," *International Journal of Advance Engineering and Research Development*, vol. 5, no. 02, 2018.
- [6] M. S. H. Sunny, D. R. Dipta, S. Hossain, H. M. R. Faruque, and E. Hossain, "Design of a Convolutional Neural Network Based Smart Waste Disposal System," May 2019. doi: 10.1109/ICASERT.2019.8934633.
- [7] G. E. Sakr, M. Mokbel, A. Darwich, M. N. Khneisser, and A. Hadi, "Comparing deep learning and support vector machines for autonomous waste sorting," in *2016 IEEE International Multidisciplinary Conference on Engineering Technology (IMCET)*, Nov. 2016, pp. 207–212. doi: 10.1109/IMCET.2016.7777453.
- [8] V. Maeda-Gutiérrez *et al.*, "Comparison of convolutional neural network architectures for classification of tomato plant diseases," *Applied Sciences (Switzerland)*, vol. 10, no. 4, Feb. 2020, doi: 10.3390/app10041245.
- [9] CCHANG, "Garbage Classification," *Kaggle*, Nov. 24, 2018.
- [10] A. Salma, "Implementation of Multilayer Perceptron for Image Classification," vol. 4, no. February, pp. 212–215, 2021.
- [11] H. Ramchoun, M. Amine, J. Idrissi, Y. Ghanou, and M. Ettaouil, "Multilayer Perceptron: Architecture Optimization and Training," *International Journal of Interactive Multimedia and Artificial Intelligence*, vol. 4, no. 1, p. 26, 2016, doi: 10.9781/ijimai.2016.415.
- [12] M. F. Naufal, "ANALISIS PERBANDINGAN ALGORITMA SVM, KNN, DAN CNN UNTUK KLASIFIKASI CITRA CUACA," *Journal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 2, pp. 311–318, 2021, doi: 10.25126/jtiik.202184553.
- [13] A. F. Agarap, "Deep Learning using Rectified Linear Units (ReLU)," no. 1, pp. 2–8, 2018, [Online]. Available: <http://arxiv.org/abs/1803.08375>
- [14] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing and Management*, vol. 45, no. 4, pp. 427–437, 2009, doi: 10.1016/j.ipm.2009.03.002.