



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

Muslihati^{1*}, Supriadi Sahibu², Imran Taufik³

^{1,2,3}Program Studi Sistem Komputer, Fakultas Ilmu Komputer, Universitas Handayani Makassar, Indonesia

E-mail: ¹cahty.idris@gmail.com, ²supriadi@handayani.ac.id, ³imran_taufik@handayani.ac.id

Received Mar 14th 2024; Revised May 5th 2024; Accepted May 20th 2024
Corresponding Author: Muslihati

Abstract

The research is aimed at implementing Convolutional Neural Network (CNN) algorithms in the classification of organic and non-organic garbage as well as measuring the accuracy of detection and identification of waste objects. CNN methods are used to detect and recognize objects in images. The results showed that the CNN model achieved the highest accuracy rate of 96.43% after six trials. The results indicate that the CNN application is worthy to be implemented in the garbage classification. It is important to perform several tests to obtain optimal accuracy results by paying attention to the datasets in the training and testing process. The conclusion of this study is that the CNN model can provide good accuracy results in the classification of organic and non-organic waste, so this application has the potential to be widely implemented.

Keywords: Algorithm, Classification, CNN, Non Organic, Organic

Abstrak

Penelitian ini bertujuan untuk mengimplementasikan algoritma Convolutional Neural Network (CNN) dalam klasifikasi sampah organik dan non-organik serta mengukur tingkat akurasi deteksi dan pengenalan objek sampah. Metode CNN digunakan untuk mendeteksi dan mengenali objek dalam citra. Hasil penelitian menunjukkan bahwa model CNN mencapai tingkat akurasi tertinggi sebesar 96.43% setelah enam kali percobaan. Hasil tersebut menunjukkan bahwa aplikasi CNN ini layak untuk diimplementasikan dalam klasifikasi sampah. Penting untuk melakukan beberapa uji coba guna memperoleh hasil akurasi yang optimal dengan memperhatikan dataset dalam proses pelatihan dan pengujian. Kesimpulan dari penelitian ini adalah bahwa model CNN dapat memberikan hasil akurasi yang baik dalam klasifikasi sampah organik dan non-organik, sehingga aplikasi ini memiliki potensi untuk diimplementasikan secara luas..

Kata Kunci: Algoritma, CNN, Klasifikasi, Non Organik, Organik

1. PENDAHULUAN

Sampah merupakan sisa pembuangan yang dihasilkan dari kegiatan manusia setiap harinya. Dalam kehidupan sehari-hari sering ditemukan kurangnya kepedulian manusia terhadap pentingnya proses pemilahan sampah sebelum dibuang, sehingga mengakibatkan terjadinya penumpukan sampah, Sampah merupakan salah satu bahan terbuang maupun dibuang yang merupakan salah satu sisa aktivitas manusia atau alam yang unsur atau fungsi utamanya telah terpakai. Sampah terbagi menjadi 2 macam yakni sampah organik dan anorganik [1].

Dapat dijelaskan bahwa sampah organik memiliki karakteristik berasal dari makhluk hidup dan merupakan sampah basah. Contoh dari sampah organik adalah dedaunan, sampah dapur, kayu, dan kotoran hewan. Sampah organik memiliki istilah lain yakni sampah degradable karena kemudahannya untuk terurai secara alami tanpa melibatkan campur tangan manusia. Berkebalikan dengan sampah anorganik, yang merupakan sampah kering dan sangat sulit untuk diuraikan (*nondegradable*). Plastik, karet, kaca dan logam merupakan contoh dari sampah anorganik [2].

Berdasarkan hasil observasi awal, di Kabupaten Mamuju khususnya pada Tempat Pembuangan Akhir (TPA) Kabupaten Mamuju, ditemukan fenomena yang menjadi masalah yang dapat diangkat menjadi sebuah penelitian. Salah satu masalah lingkungan yang dihadapi oleh pemerintahan Kabupaten Mamuju yaitu sampah

yang dihasilkan di sekitar lingkungan atau sampah yang dihasilkan oleh kegiatan sehari-hari yang tertampung pada TPA. TPA Kabupaten Mamuju merupakan wadah titik sentral penampungan utama sampah di Kabupaten Mamuju khususnya sampah dari Kecamatan Mamuju dan Kecamatan Simboro. Pada TPA Kabupaten Mamuju terdapat beberapa penampungan sampah yang kemudian menjadi tempat proses awal pengolahan sampah. Namun sampai saat ini Teknik maupun proses pemilahan dan pengolahan sampah masih sangat tidak efektif serta konvensional. Hal ini mengakibatkan terjadinya penumpukan sampah dan tidak beraturan pada TPA Kabupaten Mamuju. Hal ini sangat penting agar menjadi perhatian dari pemerintah daerah yang menanganinya, karena masalah sampah terbilang cukup serius. Menurut Undang-Undang Nomor 18 Tahun 2008 tentang Pengelolaan Sampah, "Sampah adalah sisa kegiatan sehari-hari manusia dan/atau proses alam yang berbentuk padat". Dalam hal ini dijelaskan bahwa sampah memiliki jenis yang beraneka ragam, berkaitan dengan hal tersebut maka muncullah masalah kebersihan terkait sampah lingkungan. Masalah cukup serius yang terjadi saat ini yakni masalah sampah. Sifat konsumtif masyarakat yang tidak terbatas sehingga keberadaan sampah pun tidak dapat dihindari. Berdasarkan Peraturan Daerah Kabupaten Mamuju Nomor 2 Tahun 2017 tentang Pengelolaan Sampah, menyebutkan kegiatan penanganan sampah yaitu serangkaian kegiatan yang berhubungan dengan sampah berupa pemilahan, pengumpulan, pengangkutan, pengolahan dan pemrosesan akhir sampah. Sampah merupakan masalah di seluruh dunia, terutama di negara berkembang. Masyarakat seringkali tidak memilah sampah dengan benar, sehingga sampah yang seharusnya dapat didaur ulang justru terkontaminasi dan tidak bisa lagi digunakan. Sebuah sistem diperlukan untuk membantu masyarakat dalam memilah sampah dengan benar [3], [4].

Berdasarkan data SIPSAN - Sistem Informasi Pengelolaan Sampah Nasional, Rata-rata produksi sampah harian Provinsi Sulawesi Barat khususnya Kabupaten Mamuju sekitar 132.00 ton perhari pada tahun 2020, 125.44 ton perhari pada tahun 2021 dan pada tahun 2022 meningkat menjadi 140.93 ton per hari sedangkan timbulan sampah dalam kurun waktu pertahun pada tahun 2020 sekitar 48.178.80 ton pertahun, 45.786.99 ton pertahun pada tahun 2021 dan pada tahun 2022 meningkat menjadi 51.438.36 ton pertahun. Peningkatan ini terus terjadi seiring dengan pertumbuhan penduduk dan kurangnya infrastruktur [5].

Permasalahan mengenai pemahaman jenis sampah ini dapat dipecahkan dengan klasifikasi citra [6]. Klasifikasi citra merupakan kegiatan yang didasarkan pada deteksi dan identifikasi obyek dipermukaan bumi pada citra satelit. Dengan mengenali obyek-obyek tersebut melalui unsur-unsur utama spektral dan spasial serta kondisi temporalnya [7], [8]. Dalam melakukan klasifikasi citra kita dapat memanfaatkan metode Deep Learning salah satunya yaitu dengan metode Convolutional Neural Network yang disingkat dengan (CNN). CNN adalah salah satu jenis neural network yang biasa digunakan pada data image. CNN merupakan metode yang dapat mempelajari sendiri fitur pada citra yang kompleks, yang dapat menerima input berupa gambar, menentukan aspek atau obyek apa saja dalam sebuah gambar yang bisa digunakan mesin untuk "belajar" mengenali gambar, dan membedakan antara satu gambar dengan yang lainnya [9][10].

Kelebihan dalam Algoritma CNN dalam implementasi pemilihan sampah organik dan non organik adalah dapat mengekstraksi Fitur Otomastis, dalam pemilihan sampah CNN dapat mengenali pola dan ciri-ciri khusus dari sampah organik maupun non organik seperti tekstur, warna, dan bentuk [11]. CNN Juga dapat mengelola data dalam jumlah besar, CNN memiliki lapisan-lapisan layer yang dapat mendeteksi pola dalam hal ini deteksi hirarki yang memungkinkan mendeteksi pernedaan antara sampah organik dan non organik dan CNN juga memiliki kemampuan *Transfer Learning* yang dapat dimanfaatkan untuk mempercepat proses pelatihan dan meningkatkan akurasi model dalam tugas klasifikasi [12][13].

Pada Penelitian ini menggunakan CNN karena sangat efektif dalam berbagai tugas, terutama dalam pengolahan citra dan pemahaman visual seperti CNN dapat secara otomatis mengekstrak fitur-fitur hierarkis dari data, tanpa memerlukan ekstraksi fitur manual [14]. Ini sangat berguna dalam pengolahan citra, di mana fitur-fitur penting seperti tepi, sudut, dan tekstur dapat dipelajari secara efisien dan CNN dirancang khusus untuk mengenali pola spasial dalam data gambar. Lapisan konvolusi memungkinkan model untuk mendeteksi fitur-fitur seperti tepi, bentuk, dan tekstur, yang penting dalam pemahaman visual [15][16].

Sebelumnya telah dilakukan penelitian oleh Wong, Pada penelitian ini menjelaskan terkait Pengolahan sampah yang ada pada saat ini hanya terbatas pada pengolahan sampah secara konvensional yaitu hanya diangkut dari tempat penghasil sampah ke Tempat Pembuangan Sementara (TPS) dan kemudian hanya dibuang begitu saja ke TPS tanpa dilakukan pengolahan terlebih dahulu, padahal aturan prosedur pengelolaan sampah yang harus dilakukan yaitu pengumpulan sampah kemudian didaur ulang dan dibuang ke TPS, kemudian dilakukan pengangkutan sampah yang akan dibuang di Tempat Pembuangan Akhir. Oleh karena itu, dalam proses pengelolaan sampah, perlu dilakukan pemilahan sampah menjadi sampah organik dan non-organik. Namun, kebanyakan masyarakat masih kesulitan dalam melakukan pemilahan sampah organik dan non organik, sehingga diperlukan sebuah aplikasi untuk membantu sosialisasi pemilahan sampah kepada masyarakat. Pada penelitian ini, akan digunakan metode Least Square Support Vector Machine (LS-SVM) untuk melakukan klasifikasi jenis sampah. Sementara itu, untuk melakukan proses ekstraksi tekstur dari gambar sampah yang dimasukkan, maka akan digunakan metode Gray Level Co-occurrence Matrix (GLCM). Hasil dari penelitian ini adalah sebuah aplikasi klasifikasi sampah yang dapat memberikan pengetahuan dan

menambah wawasan bagi pengguna (*user*) terutama dalam membedakan jenis sampah organik dan sampah anorganik. Penerapan metode GLCM dan LS-SVM pada aplikasi yang dibangun dapat melakukan pendeteksian jenis sampah organik dan anorganik dengan tingkat keberhasilan sebesar 97% [17].

Penelitian lainnya dengan klasifikasi menggunakan model CNN. Penelitian dengan membagi data latih sebesar 80 % dan data uji sebesar 20%, menggunakan CNN dengan dense sebanyak 128 layer dan epoch sebanyak 50 menghasilkan akurasi penuh pada data latih dan data uji. Sehingga dengan menggunakan model CNN dapat dilakukan klasifikasi gambar sampah anorganik dan organik [18]. Ada juga penelitian lainnya dengan pengujian pemilahan sampah organik dan anorganik berhasil dilakukan dengan menggunakan metode *Transfer Learning* CNN dengan menerapkan arsitektur Mobile Net. Dataset sampah yang terkumpul adalah sebanyak 5.428 di train di ML Kit. Precision 97,95% dan recall sebesar 95,18%. Pada pengujian menggunakan Android dengan library tensorflow Lite, kulit pisang dapat terdeteksi menghasilkan output sampah organik dengan akurasi sebesar 96%. Begitupun dengan sampah kardus dapat terdeteksi menghasilkan output sampah anorganik dengan akurasi sebesar 99% [19].

Melihat pentingnya permasalahan sampah tersebut seperti yang telah diuraikan pada bagian sebelumnya maka perlu untuk dilakukan penelitian terkait klasifikasi sampah organik dan anorganik dengan mengimplementasikan algoritma CNN. Pada penelitian ini akan dilakukan klasifikasi pada citra gambar sampah untuk mengenali jenis sampah organik dan non organik pada sebuah citra input.

2. METODOLOGI PENELITIAN

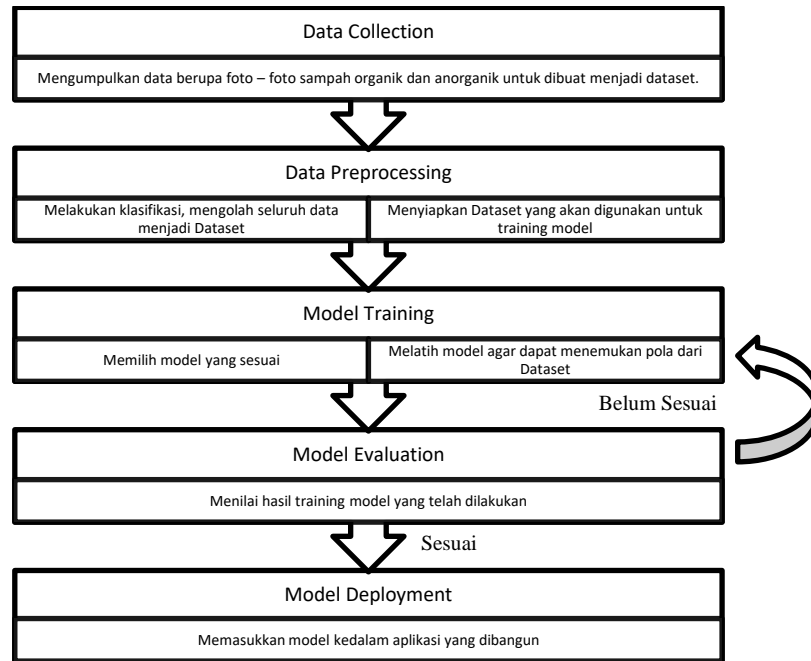
Klasifikasi adalah proses di mana ide dan objek dikenali, dibedakan, dan dipahami. Klasifikasi merupakan proses memasukkan sesuatu ke dalam kategori. Klasifikasi melibatkan menempatkan sesuatu ke dalam kelas atau kelompok menurut karakteristik tertentu sehingga lebih mudah untuk memahaminya. Proses klasifikasi dapat meliputi membedakan dan mendistribusikan jenis "hal" ke dalam kelompok yang berbeda. Hasil dari klasifikasi bisa berupa kumpulan kelas [20]. CNN merupakan salah satu metode machine pengembangan dari Multi Layer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam Deep Neural Network karena dalamnya tingkat jaringan dan banyak diimplementasikan dalam data citra [21]. CNN adalah salah satu jenis neural network yang biasa digunakan pada data citra. CNN dapat digunakan untuk mendeteksi dan mengenali objek dalam sebuah citra. CNN merupakan pengembangan dari MLP dan merupakan salah satu algoritma dari Deep Learning [22]. CNN termasuk dalam jenis jaringan saraf dalam karena kedalaman jaringannya yang tinggi dan diterapkan secara luas pada data gambar. Lapisan penyusun CNN terdiri dari Convolution Layer, Activation ReLU Layer, Pooling Layer, dan Fully Connected Layer [23].

Arsitektur CNN umumnya terdiri dari beberapa lapisan konvolusi yang diikuti oleh lapisan-lapisan lain seperti lapisan pooling, aktivasi non-linear, dan lapisan-lapisan terhubung sepenuhnya (*fully connected*) untuk melakukan klasifikasi. Lapisan-lapisan konvolusi pada CNN bertanggung jawab untuk mengekstraksi fitur-fitur lokal dari gambar, sementara lapisan-lapisan terhubung sepenuhnya di akhir arsitektur bertujuan untuk menggabungkan fitur-fitur tersebut ke dalam representasi yang lebih abstrak untuk klasifikasi [24]. Pentingnya *transfer learning* dalam CNN terutama terlihat dalam konteks penggunaannya pada dataset yang terbatas atau tugas-tugas spesifik. Dengan *transfer learning*, model CNN yang telah dilatih sebelumnya pada dataset yang besar, seperti ImageNet, dapat diadopsi dan disesuaikan dengan dataset target atau tugas-tugas yang berbeda. Ada beberapa pendekatan dalam *transfer learning*, salah satunya adalah *fine-tuning*, di mana lapisan-lapisan konvolusi awal dari model CNN di-finetune dengan dataset target sementara lapisan-lapisan yang lebih tinggi dipelihara. Pendekatan lainnya adalah penggunaan model CNN sebagai ekstraktor fitur, di mana lapisan-lapisan konvolusi awal dari model CNN dipertahankan sebagai ekstraktor fitur dan diikuti oleh lapisan-lapisan klasifikasi baru yang dilatih dengan dataset target [25].

Optimizer merupakan komponen kunci dalam proses pelatihan model neural network, termasuk CNN, yang bertanggung jawab untuk menyesuaikan parameter-parameter model agar dapat meminimalkan nilai fungsi kerugian (*loss function*) saat melakukan pelatihan dengan menggunakan data pelatihan yang ada. Ada berbagai jenis optimizer yang digunakan, seperti Stochastic Gradient Descent (SGD), Adam, RMSprop, dan Adagrad, yang masing-masing memiliki cara kerja dan kelebihan tersendiri [26]. Pemilihan optimizer yang tepat memainkan peran penting dalam kecepatan dan kualitas konvergensi model selama proses pelatihan, dengan mempertimbangkan jenis data, ukuran dataset, kompleksitas model, serta pengaturan *hyperparameter* seperti *learning rate* dan momentum untuk mencapai kinerja optimal [27].

Jenis Penelitian yang digunakan dalam penelitian ini adalah Eksperimental, Pengembangan dan Komparatif. Jenis Penelitian Eksperimental ini Mengukur dan mengevaluasi kinerja algoritma CNN dalam mengklasifikasikan sampah menjadi dua kategori non-organik dan organik, dengan tahapan Mengumpulkan dataset sampah yang mencakup kedua kategori, Melatih model menggunakan algoritma CNN, Mengevaluasi kinerja model menggunakan metrik seperti akurasi, presisi, recall, dan F1-score. Jenis Penelitian Pengembangan untuk Mengembangkan sistem atau model klasifikasi sampah berbasis algoritma CNN, dan Jenis Penelitian Komparatif untuk membandingkan kinerja algoritma CNN dengan algoritma klasifikasi lainnya dalam konteks klasifikasi sampah.

Penelitian ini akan melalui beberapa tahap yang saling terhubung dan berdampak satu sama lain secara berurutan untuk mencapai hasil yang diinginkan. Proses penelitian ini disusun dalam serangkaian tahapan yang dijalankan berurutan, di mana setiap tahapan memiliki keterkaitan yang erat dengan tahapan sebelumnya dan setelahnya. Penjelasan terperinci mengenai serangkaian tahapan ini dapat ditemukan dalam Gambar 1 yang disertakan.



Gambar 1. Tahapan Penelitian

1. *Data Collection*

Pengumpulan data berupa gambar dengan format file jpg maupun png yang diperoleh dari hasil pengambilan gambar secara langsung maupun yang diperoleh dari website kaggle. Total gambar yang dikumpulkan sebanyak 150 untuk citra gambar sampah organik dan 163 citra gambar untuk sampah non organik.

2. *Data Preprocessing*

Tahap selanjutnya data dibagi dalam 2 (dua) kelas yaitu organik dan non organik, kemudian dilakukan pembagian data *training* dan data uji. Dari dataset yang digunakan dilakukan pembagian dengan persentase 80% data *training* dan 20% data *test* untuk untuk masing-masing dataset sampah organik dan sampah non organik.

3. *Model Training*

Tahap selanjutnya adalah melatih model menggunakan data yang telah di-*preprocessing*. Model yang digunakan adalah sebanyak 6 model dengan 3 variasi split data untuk model CNN dengan 3 konvolusi (60:40, 70:30 dan 80:20) dan 3 model CNN dengan *transfer learning* (VGG16, Xception dan NasNet Mobile).

4. *Model Evaluation*

Setelah model dilatih, perlu dilakukan evaluasi untuk mengukur kinerja model. Evaluasi dapat dilakukan dengan menggunakan data yang tidak digunakan untuk melatih model. Data tersebut disebut sebagai data testing. Evaluasi dapat dilakukan dengan menghitung akurasi, presisi, F1 score dan recall model.

5. *Model Deployment*

Setelah model dievaluasi dan diperoleh kinerja yang terbaik baik, maka selanjutnya model dapat di-deploy untuk digunakan dalam aplikasi klasifikasi sampah organik dan non organik.

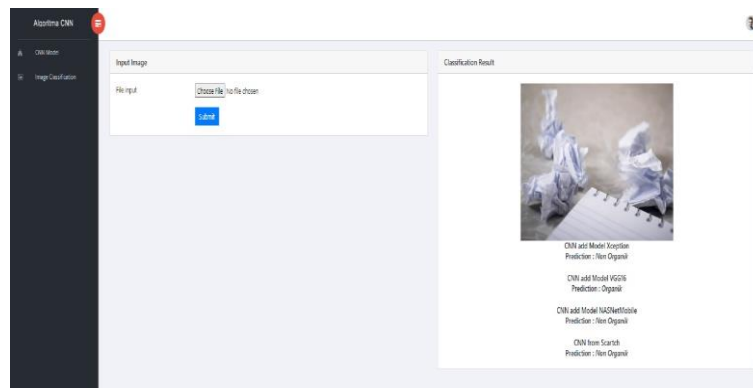
3. HASIL DAN PEMBAHASAN

3.1. Hasil Penelitian

Tahap implementasi dilakukan implementasi system yaitu model yang telah dibentuk pada python kemudian di deploy kedalam bentuk website dimana ketika ada citra gambar baru maka akan dilakukan classification image yang baru sehingga menampilkan hasil akurasi dari citra gambar sampah. Berikut ini merupakan uraian dari aplikasi klasifikasi sampah organik dan non organik.

1. Menu *Input* Aplikasi

Merupakan menu *input* citra gambar sampah ketika akan melakukan uji coba terhadap data yang baru dimana dengan menginput citra gambar dengan melakukan proses klasifikasi dengan algoritma CNN maka akan menghasilkan hasil klasifikasi sesuai dengan *output* sampah organik dan sampah non organik.

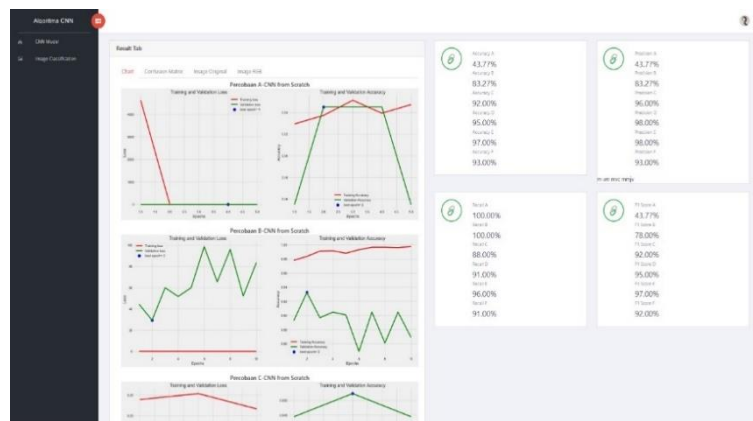


Gambar 1. Menu Input Aplikasi

Gambar 1. *User* akan menginput data gambar pada kolom file *input* kemudian menekan tombol *submit*, setelah itu sistem akan mencerna gambar dan melakukan proses klasifikasi, selanjutnya gambar yang telah diinput sebelumnya akan ditampilkan bersamaan dengan hasil prediksi untuk masing-masing model yang digunakan pada kolom hasil di sebelah kanan layar.

2. Hasil Pengujian


Merupakan hasil pengujian dari model CNN dengan 6 kali percobaan.



Gambar 2. Hasil Pengujian Pada Website

Gambar 2. Chart dari hasil percobaan menunjukkan tingkat *loss* dan *accuracy* untuk masing-masing percobaan, semakin rendah nilai *loss* pada proses *epoch* maka akan semakin bagus hasil *accuracy* data *training*, sedangkan di bagan kanan menunjukkan *summary* tingkat akurasi yang berbeda-beda untuk masing-masing percobaan dimana pada percobaan awal memperoleh hasil akurasi 43.77%, percobaan kedua dengan 83.27%, percobaan ketiga 92.00%, percobaan ke empat dengan 95.00%, percobaan kelima dengan 97.00% dan percobaan ke enam dengan tingkat akurasi sebanyak 93.00%.

Tahapan proses pengujian model A untuk klasifikasi sampah organik dan non organik maka akan menampilkan hasil *confusion matrix* dan nilai akurasi seperti pada gambar Gambar 3.



Gambar 3. Hasil Pengujian *Confusion Matrix A*

Gambar 3. merupakan matriks hubungan pada saat tahapan proses pengujian model CNN maka akan menampilkan hasil nilai akurasi *confusion matrix* 2x2 seperti pada gambar 3 dimana pada *matrix* tersebut menampilkan hasil dengan sampah organik sebesar 42 dan non oraganik sebesar 41. Hasil *Confusion Matrix A* ditunjukkan pada tabel 1.


Tabel 1. Hasil *Confusion Matrix A*

	Precision	Recall	F1 Score
Non Organik	0,00	0,00	0,00
Organik	0,51	1,00	0,67
Accuracy			0,51

Hasil nilai akurasi yang diperoleh dari pegujian model Matrix A sebesar 51% yang proses perhitungannya berdasarkan jumlah nilai dari diagonal *Confusion Matrix* dibagi dengan jumlah seluruh data.

1. Hasil Pengujian *Confusion Matrix B*

Pada saat tahapan proses pengujian model B untuk klasifikasi sampah organik dan non organik maka akan menampilkan hasil *confusion matrix* dan nilai akurasi seperti pada gambar 4.



Gambar 4. Hasil Pengujian *Confusion Matrix B*

Gambar 4. merupakan matriks hubungan pada saat tahapan proses pengujian model CNN maka akan menampilkan hasil nilai akurasi *confusion matrix* 2x2 seperti pada gambar diatas dan menghasilkan Classification report seperti pada tabel 2.


Tabel 2. Hasil *Confusion Matrix B*

	Precision	Recall	F1 Score
Non Organik	0,82	0,62	0,71
Organik	0,72	0,88	0,79
Accuracy			0,76

Hasil nilai akurasi yang diperoleh dari pegujian model Matrix B sebesar 76% yang proses perhitungannya berdasarkan jumlah nilai dari diagonal *Confusion Matrix* dibagi dengan jumlah seluruh data.

2. Hasil Pengujian *Confusion Matrix* C

Pada saat tahapan proses pengujian model C untuk klasifikasi sampah organik dan non organik maka akan menampilkan hasil *confusion matrix* dan nilai akurasi seperti pada gambar 5.



Gambar 5. Hasil Pengujian *Confusion Matrix* C

Gambar 5. merupakan matriks hubungan pada saat tahapan proses pengujian model CNN maka akan menampilkan hasil nilai akurasi *confusion matrix* 2x2 seperti pada gambar diatas dan menghasilkan hasil pengujian akurasi seperti pada tabel 3.


Tabel 3. Hasil *Confusion Matrix* C

	Precision	Recall	F1 Score
Non Organik	0,71	0,71	0,71
Organik	0,60	0,60	0,60
Accuracy	0,67		

Hasil nilai akurasi yang diperoleh dari pegujian model Matrix C sebesar 67% yang proses perhitungannya berdasarkan jumlah nilai dari diagonal *Confusion Matrix* dibagi dengan jumlah seluruh data.

3. Hasil Pengujian *Confusion Matrix* D

Pada saat tahapan proses pengujian model D untuk klasifikasi sampah organik dan non organik maka akan menampilkan hasil *confusion matrix* dan nilai akurasi seperti pada gambar 6. Jika dilihat pada gambar 6. merupakan matriks hubungan pada saat tahapan proses pengujian model CNN maka akan menampilkan hasil nilai akurasi *confusion matrix* 2x2 seperti pada gambar tersebut dan menghasilkan hasil pengujian akurasi seperti pada tabel 4.



Gambar 6. Hasil Pengujian *Confusion Matrix* D

Tabel 4. Hasil *Confusion Matrix D*

	Precision	Recall	F1 Score
Non Organik	0,80	0,62	0,70
Organik	0,72	0,87	0,79
Accuracy			0,75

Hasil nilai akurasi yang diperoleh dari pegujian model *Matrix D* sebesar 75% yang proses perhitungannya berdasarkan jumlah nilai dari diagonal *Confusion Matrix* dibagi dengan jumlah seluruh data.

Tabel 5. Tabel Hasil Pengujian

No	Objek	Aktual	Prediksi	Ket
1		Organik	Organik	TN
2		Organik	Organik	TN
3		Organik	Organik	TN
4		Non Organik	Non Organik	TP
5		Non Organik	Organik	FP
6		Non Organik	Non Organik	TP

Berdasarkan table diatas, diketahui nilai *True Positive* (TP) 2, *False Positive* (FP) 1, *True Negative* (TN) 3, dan *False Negative* (FN) 0. Maka dapat dihitung nilai *confusion matrix* sebagai berikut:

- a. *Accuracy*, yaitu ukuran sejauh mana model klasifikasi mampu memprediksi dengan benar keseluruhan sampel.

$$\begin{aligned}
 \text{Akurasi} &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\
 &= \frac{5}{6} \times 100\% \\
 &= 0,83 \times 100\% = 83\%
 \end{aligned}$$

- b. *Precision* mengukur sejauh mana model mampu memprediksi dengan benar positif yang sebenarnya dari semua prediksi positif yang dibuat oleh model.

$$\begin{aligned} \text{Presisi} &= \frac{TP}{TP + FP} \times 100\% \\ &= \frac{2}{3} \times 100\% \\ &= 0,67 \times 100\% = 67\% \end{aligned}$$

- c. *Recall* mengukur sejauh mana model mampu mendeteksi dengan benar semua sampel positif yang seharusnya diprediksi sebagai positif.

$$\begin{aligned} \text{Recall} &= \frac{TP}{TP + FN} \times 100\% \\ &= \frac{2}{2} \times 100\% \\ &= 1 \times 100\% = 100\% \end{aligned}$$

- d. Skor F1 adalah metrik gabungan yang menggabungkan presisi dan recall untuk memberikan pemahaman yang lebih baik tentang kinerja model secara keseluruhan.

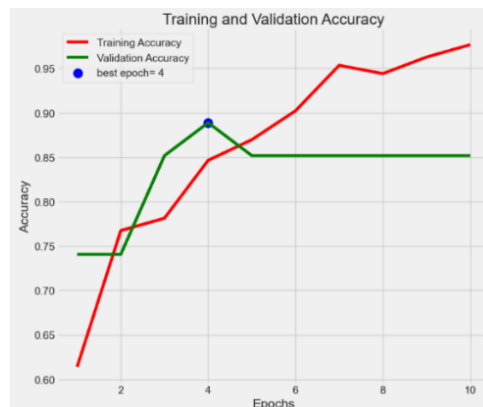
$$\begin{aligned} \text{Skor F1} &= \frac{2 \times \text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \times 100\% \\ &= \frac{2 \times 0,67 \times 1}{0,67 + 1} \times 100\% \\ &= \frac{1,34}{1,67} \times 100\% = 0.80 \times 100\% = 80\% \end{aligned}$$

3.2 Hasil Analisis

Pada tahap ini dilakukan uji coba untuk menghasilkan validasi data *training validation accuracy* dan *validation loss* seperti pada gambar grafik berikut ini:

1. Grafik *Training and Validation Accuracy*

Pada saat tahapan proses evaluasi pengujian untuk klasifikasi sampah organik dan non organik maka akan menampilkan hasil evaluasi berupa grafik seperti pada gambar 7.




Gambar 7. Grafik *Training Validation Accuracy*

Gambar 7. merupakan grafik yang menggambarkan *training* dan *validation accuracy* dimana dalam grafik tersebut dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi training (tren merah) sebesar 96% hasil akurasi. Grafik dari model CNN yang dibuat dengan tingkat akurasi pada data *training* (tren merah) memperoleh 0.96% dan data testing (tren hijau) memperoleh 0.89%.

2. Grafik *Training and Validation Loss*


Pada saat tahapan proses evaluasi pengujian untuk klasifikasi sampah organik dan non organik akan menampilkan hasil Evaluasi berupa grafik seperti pada gambar 8.



Gambar 8. Grafik *Training Validation Loss*

Pada gambar 8 merupakan hasil validasi uji coba pertama dimana hasil ujicoba tersebut menampilkan grafik loss dari model *Convolution Neural Network (CNN)* yang dibuat dengan tingkat Loss pada data training (tren merah) memperoleh 0.1% dan data testing (tren hijau) memperoleh 0.75%.

3. Grafik *Training and Validation Accuracy (Epoch 50)*



Gambar 9. Grafik *Training Validation accuracy*

Gambar 9. merupakan grafik yang menggambarkan *training* dan *validation* accuracy dimana dalam grafik tersebut dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi *training* (tren merah) sebesar 96% hasil akurasi. Grafik dari model CNN yang dibuat dengan tingkat akurasi pada data *training* (tren merah) memperoleh 1.00% dan data *testing* (tren hijau) memperoleh 0.85%.


4. Grafik *Training and Validation Loss (Epoch 50)*

Pada gambar 10 merupakan hasil validasi uji coba pertama dimana hasil ujicoba tersebut menampilkan grafik *loss* dari model CNN yang dibuat dengan tingkat *loss* pada data *training* (tren merah) memperoleh 0.0% dan data *testing* (tren hijau) memperoleh 0.9%.



Gambar 10. Grafik *Training Validation Loss*

5. Grafik *Training and Validation Accuracy (Epoch 100)*



Gambar 11. Grafik *Training Validation Accuracy*

Gambar 11. merupakan grafik yang menggambarkan *training* dan *validation accuracy* dimana dalam grafik tersebut dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi *training* (tren merah) sebesar 96% hasil akurasi. Grafik dari model CNN yang dibuat dengan tingkat akurasi pada data *training* (tren merah) memperoleh 1.00% dan data *testing* (tren hijau) memperoleh 0.82%.

6. Grafik *Training and Validation Loss (Epoch 100)*



Gambar 12. Grafik *Training Validation Accuracy*

Pada gambar 11. merupakan hasil validasi uji coba pertama dimana hasil uji coba tersebut menampilkan grafik *loss* dari model CNN yang dibuat dengan tingkat *loss* pada data *training* (tren merah) memperoleh 0.0% dan data *testing* (tren hijau) memperoleh 0.9%.

3.3 Pembahasan

1. Hasil Validasi Akurasi

Berdasarkan hasil validasi akurasi dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi *training* sebesar 51% hasil akurasi. Grafik dari model CNN yang dibuat dengan tingkat akurasi pada data *training* memperoleh 0.51 dan data *testing* memperoleh 0.50.

2. Hasil Klasifikasi

Dengan melakukan uji coba terhadap data yang baru dimana dengan menginput citra gambar dengan melakukan proses klasifikasi dengan algoritma CNN maka akan menghasilkan hasil klasifikasi sesuai dengan output sampah organik dan sampah non organik

3. Hasil Uji Model CNN

Berdasarkan hasil pengujian dari model CNN dengan 6 kali percobaan dengan tingkat akurasi yang berbeda-beda seperti yang ditampilkan pada tabel 6.

Tabel 6. Tabel Hasil Pengujian *Confusion Matriks*

No	Uji Coba	Model	Data Training	Data Testing	Akurasi
1	Uji Coba A	-	70%	30%	51%
2	Uji Coba B	-	60%	40%	76%
3	Uji Coba C	-	80%	20%	67%
4	Uji Coba D	Model VGG16	80%	20%	75%
5	Uji Coba E	Model Xception	80%	20%	96%
6	Uji Coba F	Model NasNet Mobile	80%	20%	82%

Pada percobaan awal memperoleh hasil akurasi 50.60%, percobaan kedua dengan 75.64%, percobaan ketiga 66.67%, percobaan ke empat dengan 75.00%, percobaan kelima dengan 96.43% dan percobaan ke enam dengan tingkat akurasi sebanyak 82.14%. dalam hal ini untuk memperoleh hasil akurasi yang baik perlu dilakukan beberapa kali uji coba sehingga memperoleh hasil akurasi yang baik dengan memperhatikan dataset sebagai langkah untuk melakukan uji coba berdasarkan data training dan data testing.

4. KESIMPULAN

Berdasarkan hasil analisis klasifikasi sampah organik dan non-organik menggunakan metode CNN, kami menyimpulkan hal-hal berikut. Pertama, metode CNN terbukti efektif untuk mengklasifikasikan sampah organik dan non-organik berdasarkan dataset yang digunakan. Kedua, penelitian ini memberikan kontribusi dalam menawarkan solusi untuk pengelolaan sampah dengan mengidentifikasi jenis sampah secara otomatis melalui pendekatan berbasis CNN. Ketiga, peningkatan jumlah data latih menunjukkan peran krusial dalam meningkatkan kinerja model dengan memungkinkannya untuk memahami variasi yang lebih luas dalam dataset, mengurangi risiko *overfitting*, dan meningkatkan kemampuannya untuk menggeneralisasi pada data baru. Tambahan informasi, hasil dari enam kali percobaan menunjukkan bahwa CNN dengan model Exception mencapai kinerja terbaik dengan tingkat akurasi mencapai 96%, menegaskan kehandalan metode tersebut dalam tugas klasifikasi sampah.

UCAPAN TERIMAKASIH

Terimakasih kepada semua pihak yang telah berpartisipasi dan memberikan kontribusi berharga dalam penelitian ini. Ucapan terima kasih kami sampaikan kepada seluruh individu dan lembaga yang telah memberikan bantuan serta dukungan yang luar biasa dalam memperlancar jalannya penelitian ini. Adapun kepada semua yang telah memberikan dukungan, nasihat, dan bantuan teknis selama proses penelitian, kami ingin mengucapkan rasa terima kasih yang sebesar-besarnya atas kontribusi yang berarti bagi kelancaran penyelesaian penelitian ini.

REFERENSI

- [1] I. Febriadi, "Pemanfaatan Sampah Organik Dan Anorganik Untuk Mendukung Go Green Concept Di Sekolah," *Abdimas: Papua Journal of Community Service*, vol. 1, no. 1, pp. 32–39, Feb. 2019, doi: 10.33506/pjcs.v1i1.348.
- [2] Z. Tirta Maulitia *et al.*, "Pemanfaatan Sampah Organik dan Anorganik sebagai Salah Satu Upaya Pengelolaan Sampah di Desa Deles, Batang (Utilization of Organic and Inorganic Waste as Waste Management Efforts in Deles Village, Batang)," *Jurnal Pusat Inovasi Masyarakat*, vol. 4, no. 2, pp. 179–187, 2022.
- [3] A. Anas, "Akuntabilitas Penyelenggaraan Pengelolaan Sampah Kota Di Kabupaten Mamuju Provinsi Sulawesi Barat," Universitas Terbuka, Jakarta, 2017.
- [4] M. C. Hairuddin, S. Rahmah, P. Studi, K. Lingkungan, and K. Mamuju, "ANALISIS TIMBULAN SAMPAH DI KANTOR GUBERNUR PROVINSI SULAWESI BARAT," 2020.
- [5] Kementerian Lingkungan Hidup dan Kehutanan, "Sistem Informasi Pengelolaan Sampah Nasional," Kementerian Lingkungan Hidup dan Kehutanan. Accessed: May 07, 2024. [Online]. Available: <https://sipsn.menlhk.go.id/sipsn/public/data/timbulan>
- [6] M. Fahmi, A. Yudhana, and S. Sunardi, "Pemilahan Sampah Menggunakan Model Klasifikasi Support Vector Machine Gabungan dengan Convolutional Neural Network," *JURKOM (Jurnal Riset Komputer)*, vol. 10, no. 1, pp. 76–81, 2023, doi: 10.30865/jurikom.v10i1.5468.
- [7] F. Sawitri, "INTEGRATION OF GIS AND MCDM METHODS FOR THE EVALUATION OF SOLAR FARM LOCATIONS, CASE STUDY IN KUPANG REGENCY, EAST NUSA TENGGARA," Institut Teknologi Sepuluh Nopember, Surabaya, 2016.
- [8] P. S. Putri, D. Dasrizal, and A. Z. P. Ulmi, "DISTRIBUSI DAN POLA SPASIAL USAHA COFFEE SHOP DI KECAMATAN BANGKO PROVINSI JAMBI," *Jurnal Pendidikan Geografi Undiksha*, vol. 9, no. 3, pp. 217–233, 2021, doi: <http://dx.doi.org/10.23887/jjppg.v9i3.38068>.

- [9] D. Tribuana, H. Hazriani, and A. Latief Arda, "Face recognition for smart door security access with convolutional neural network method," *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 22, no. 3, pp. 702–710, Jun. 2024, doi: 10.12928/telkomnika.v22i3.25946.
- [10] E. Juniari, "KLASIFIKASI CITRA UNTUK PENGELOMPOKAN SAMPAH DENGAN MENGGUNAKAN CONVOLUTION NEURAL NETWORK," Nusa Putra University, Sukabumi, 2022.
- [11] 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, Apr. 2021, doi: 10.29207/resti.v5i2.2754.
- [12] M. Raffly Alwanda, R. Putra, K. Ramadhan, and D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," 2020.
- [13] R. Permana, H. Saldu, and D. I. Maulana, "OPTIMASI IMAGE CLASSIFICATION PADA JENIS SAMPAH DENGAN DATA AUGMENTATION DAN CONVOLUTIONAL NEURAL NETWORK," *Jurnal Sistem Informasi dan Informatika (Simika)*, vol. 5, 2022.
- [14] D. Tribuana, H. Hazriani, and A. Latief Arda, "Image Preprocessing Approaches Toward Better Learning Performance with CNN," *JURNAL RESTI (Rekayasa Sist. Teknol. Inf.)*, vol. 10, no. 1, pp. 1–9, 2024, doi: 10.29207/resti.v8i1.5417.
- [15] A. T. Setiawan, "Identifikasi Jenis Sampah Secara Otomatis Menggunakan Metode Convolutional Neural Network (CNN)," *Smart Comp*, vol. 11, no. 3, pp. 345–357, 2022.
- [16] J. L. Setiani, "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR RESNET50 UNTUK IDENTIFIKASI JENIS SAMPAH PLASTIK," Universitas Atma Jaya, Yogyakarta, 2020.
- [17] J. Wong, "Aplikasi Klasifikasi Sampah Organik dan Non Organik dengan Metode GLCM Dan LS-SVM," *Bulletin of Computer Science Research*, vol. 3, no. 1, pp. 83–89, 2022, doi: 10.47065/bulletincsr.v3i1.198.
- [18] A. Ibnul Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 1, Apr. 2022, doi: 10.28932/jutisi.v8i1.4314.
- [19] S. Alden and B. N. Sari, "Implementasi Algoritma CNN Untuk Pemilahan Jenis Sampah Berbasis Android Dengan Metode CRISP-DM," *Jurnal Informatika*, vol. 10, no. 1, pp. 62–71, Mar. 2023, doi: 10.31294/inf.v10i1.14985.
- [20] I. Kasim, Y. Yuyun, and S. Sahibu, "KLASIFIKASI SURAT DIGITAL MENGGUNAKAN ALGORITMA NAÏVE BAYES," *Jurnal IT Media Informasi IT STMIK Handayani*, vol. 13, no. 2, pp. 57–62, 2020.
- [21] O. D. S. Sunanto and P. H. Utomo, "IMPLEMENTASI DEEP LEARNING DENGAN CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI GAMBAR SAMPAH ORGANIK DAN ANORGANIK," *Seminar Nasional Matematika, Geometri, Statistika, dan Komputasi SeNa-MaGeStiK*, 2022, [Online]. Available: <https://magestic.unej.ac.id/>
- [22] A. Peryanto, A. Yudhana, and R. Umar, "Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation," 2020. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [23] R. Permana, H. Saldu, and D. I. Maulana, "OPTIMASI IMAGE CLASSIFICATION PADA JENIS SAMPAH DENGAN DATA AUGMENTATION DAN CONVOLUTIONAL NEURAL NETWORK," *Jurnal Sistem Informasi dan Informatika (Simika)*, vol. 5, 2022.
- [24] M. Khairunnas, "PENGUNAAN METODE DEEP LEARNING EFFICIENTNET-B1 UNTUK MENGENALI SAMPAH ORGANIK DAN SAMPAH ANORGANIK," Universitas Negeri Sultan Syarif Kasim Riau, Pekanbaru, 2021.
- [25] A. A. A. Paliwang, M. R. D. Septian, M. Cahyanti, and E. R. Swedia, "KLASIFIKASI PENYAKIT TANAMAN APEL DARI CITRA DAUN DENGAN CONVOLUTIONAL NEURAL NETWORK," *SEBATIK*, vol. 24, no. 2, pp. 207–212, 2020.
- [26] S. Shedriko and M. Firdaus, "PERBANDINGAN OPTIMIZER ADAGRAD, ADADELTA DAN ADAM DALAM KLASIFIKASI GAMBAR MENGGUNAKAN DEEP LEARNING," *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 8, no. 1, pp. 103–109, 2023.
- [27] R. Richo, R. Yudha Adhitya, M. Khoiril Hasin, M. Syai'in, and E. Setiawan, "Analisis Pengaruh Optimizer pada Model CNN untuk Identifikasi Cacat pada Perekat Kemasan Optimizer Analysis on the CNN Model for Identification Packaging Defects," *Jurnal Sisfotenika*, vol. 13, no. 2, pp. 217–229, 2023, doi: 10.30700/jst.v13i2.1447.