

Penerapan Algoritma *Deep Learning* CNN untuk Klasifikasi Pemilahan Sampah

Salwa Rona Sausan Claudia[#], Yani Parti Astuti

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro
Jln. Imam Bonjol 207, Kota Semarang, 50131, Indonesia
[#]111202012517@mhs.dinus.ac.id

Abstrak

Indonesia merupakan negara ke-4 yang menghasilkan sampah terbanyak di dunia. Hal ini menyebabkan salah satu kota di Indonesia dijuluki dengan "The City of Pigs". Jumlah sampah di Indonesia terbilang cukup tinggi yaitu mencapai 21,1 juta ton. Dengan banyaknya jumlah sampah di Indonesia, maka diperlukannya sistem identifikasi untuk membantu proses pengolahan sampah. Penelitian ini bertujuan untuk membangun aplikasi klasifikasi sampah dengan metode *deep learning*. Pada sistem identifikasi ini membutuhkan suatu dataset dan sistem klasifikasi. Dataset yang digunakan dalam sistem identifikasi berupa citra objek yang terdiri dari beberapa jenis, yaitu plastik, kardus, kaca, kaleng, kertas, dan sampah bungkus. Lalu, untuk sistem klasifikasi menggunakan model *image classification*. Sistem telah berhasil mengidentifikasi jenis sampah menggunakan algoritma *Convolutional Neural Network* (CNN) dengan baik. Model CNN dijalankan dengan beberapa layer dataset citra sampah yang telah dikumpulkan digunakan untuk proses pelatihan dan proses pengujian. Penelitian ini dijalankan dengan lima layer yaitu *Convolutional Layers*, *Max Pooling Layers*, *Flatten Layers*, *AveragePooling2D*, dan *Dense Layers*. Setelah model dijalankan, selanjutnya dilakukan proses pelatihan dan dilakukan pengujian menggunakan model CNN untuk mengklasifikasi gambar. Hasil dari penelitian ini berupa nilai akurasi data 81,08% dan prediksi model untuk 10 sampel data pengujian, beserta dengan label prediksi dan label sebenarnya.

Kata kunci: klasifikasi sampah, *deep learning*, *Convolutional Neural Network*, *image classification*

Abstract

Indonesia is the 4th country that produces the most waste in the world. This has caused one of the cities in Indonesia to be nicknamed "The City of Pigs". The amount of waste in Indonesia is quite high, reaching 21.1 million tons. With the large amount of waste in Indonesia, an identification system is needed to assist the waste processing process. This research aims to build a waste classification application using deep learning methods. This identification system requires a dataset and a classification system. The dataset used in the identification system is in the form of object images consisting of several types, namely plastic, cardboard, glass, cans, paper and packaging waste. Then, for the classification system using the *image classification* model. The system has succeeded in identifying types of waste using the *Convolutional Neural Network* (CNN) algorithm well. The CNN model is run with several layers of garbage image datasets that have been collected and used for the training and testing processes. This research was carried out with five layers, namely *Convolutional Layers*, *Max Pooling Layers*, *Flatten Layers*, *AveragePooling2D*, and *Dense Layers*. After the model is run, the training process is then carried out and tested using the CNN model to classify images. The results of this research are data accuracy values of 81.08% and model predictions for 10 test data samples, along with predicted labels and actual labels.

Keywords: garbage classification, *deep learning*, *Convolutional Neural Network*, *image classification*

I. PENDAHULUAN

Sampah saat ini menjadi salah satu permasalahan utama di Indonesia. Sampah adalah masalah yang sering kita jumpai sehari-hari. Selain itu, kegiatan sehari-hari yang kita lakukan pasti menghasilkan

sampah. Sampah merupakan bahan yang sudah tidak terpakai dari hasil sisa aktivitas manusia. Jumlah sampah rumah tangga memiliki potensi paling besar dalam menyumbang jumlah sampah di Indonesia. Jumlah sampah yang tertimbun di Indonesia pada tahun 2022 berdasarkan data Sistem

Informasi Pengelolaan Sampah Nasional mencapai 21.1 juta ton. Dari total tersebut, 65,71% (13,9 juta ton) sampah sudah terkelola dengan baik, sedangkan 34,29% (7,2 juta ton) sisanya belum terkelola. Salah satu cara pengelolaan sampah yang dianjurkan yaitu dengan proses daur ulang. Daur ulang adalah pengolahan kembali bahan-bahan bekas dalam bentuk sampah kering yang nilai ekonomisnya rendah atau bahkan tidak mempunyai nilai ekonomis menjadi suatu barang yang berharga dan berguna bagi kehidupan manusia [1]. Ada beberapa langkah yang harus diperhatikan sebelum melakukan proses daur ulang. Pertama, sampah harus dikumpulkan. Kedua, sampah dipilah sesuai jenis dan bahannya. Selanjutnya proses manufaktur, sampah yang sudah dipilah dapat didaur ulang sesuai jenisnya. Proses daur ulang mayoritas menggunakan tenaga manusia. Maka dari itu kesalahan dalam proses pemilahan sampah itu sering terjadi saat di lapangan karena para pekerja rentan bingung pada saat proses pemilahan sampah jika jumlah sampah yang di pilah itu sangat banyak [2].

Proses pemilahan sampah yang telah dilakukan penelitian menggunakan berbagai algoritma untuk membuat sistem klasifikasi sampah. Beberapa algoritma telah diterapkan untuk klasifikasi sampah antara lain *Support Vector Machine* (SVM), *K-Nearest Neighbor* (KNN), *Convolutional Neural Network* (CNN), *Multilayer Perceptron* (MLP), dll. [3]. SVM dan KNN sangat bagus untuk diimplementasikan pada pemilahan sampah pada kondisi normal dimana citranya jelas dan mudah dibedakan [4]. Namun, algoritma yang dapat bekerja dengan baik untuk klasifikasi gambar yaitu algoritma CNN. CNN merupakan algoritma *deep learning* yang terkenal sebagai pendekatan yang menghasilkan hasil yang menjanjikan di berbagai bidang, termasuk *image recognition*, *speech recognition*, dan *face recognition* [5], [6]. CNN salah satu algoritma *deep learning* yang populer dalam melakukan pengolahan citra. Hal ini dikarenakan CNN mempunyai tingkat akurasi yang tinggi dalam klasifikasi citra. Keakuratan pada CNN sangat diperlukan untuk meningkatkan ketepatan proses pemilahan sampah yang cukup sulit di Indonesia.

Penelitian terkait [7] yang telah melakukan deteksi objek yang menggunakan metode *Faster-RCNN*. Penelitian ini dikembangkan sebuah metode yang dapat mengidentifikasi botol plastik. Proses klasifikasi botol plastik berdasarkan mereknya menggunakan algoritma CNN. Model yang digunakan untuk media pendukung dalam pembelajaran mesin untuk mengidentifikasi botol plastik berdasarkan merek yaitu model *Faster-*

RCNN. Hasil penelitian ini berupa nilai total rata-rata akurasi dengan jumlah 87,21%. Penelitian selanjutnya [8] melakukan pemilahan sampah menggunakan robot dengan klasifikasi objek sampah berbasis jaringan saraf dan menggunakan model *Faster-RCNN*. Klasifikasi ini memperoleh gambar dari kamera dan menentukan jenis objek. Dataset yang digunakan lebih dari 14.000 gambar objek. Penelitian ini menggunakan jenis objek botol *High Density Polyethylene* (HDPE), botol *Polyethylene Terephthalate* (PET), dan aluminium. Hasil penelitian mendapatkan nilai akurasi 64%. Penelitian selanjutnya [9] mendeteksi berbagai jenis sampah menggunakan 3 algoritma, yaitu algoritma CNN, *You Only Look Once* (YOLO), dan *Region based Convolutional Neural Network* (R-CNN). Algoritma tersebut dibandingkan untuk mendapatkan nilai akurasi tertinggi, kerugian terkecil dan waktu pelatihan tercepat. Untuk hasil klasifikasi algoritma CNN tingkat akurasi 80% dengan kegagalan 60% dan memiliki waktu pelatihan tercepat. Algoritma YOLO membutuhkan waktu lebih lama untuk pelatihan, tetapi memiliki tingkat akurasi lebih tinggi dan tingkat kegagalan lebih rendah dari algoritma CNN dengan persentase akurasi 88% dan kegagalan 40%. Lalu, algoritma R-CNN memiliki akurasi tertinggi yaitu 91% dan kegagalan 16%, sedangkan waktu pelatihan R-CNN tercepat dibandingkan 2 algoritma lainnya.







Tujuan dari penelitian ini untuk menerapkan metode CNN pada sistem klasifikasi citra sampah. Penelitian yang telah dilakukan diharapkan dapat membantu proses pemilahan sampah dengan metode CNN.

II. METODE PENELITIAN

A. Proses Pengumpulan Data

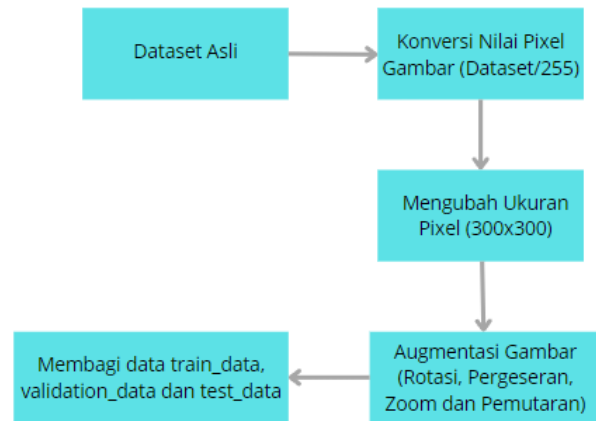
Penelitian ini menggunakan dataset berupa data gambar sampah. Data yang digunakan merupakan data privat. Jumlah dataset yang telah dikumpulkan yaitu 1840 citra jenis sampah yang dibagi menjadi 6 kategori yaitu *plastic*, *metal*, *paper*, *glass*, *cardboard*, dan *others* seperti ditunjukkan pada Tabel 1. Dataset gambar jenis sampah berformat jpg dan ukuran pixel 4160 x 3120.

Tabel 1. Jenis dataset

| No | Jenis sampah | Citra Sampah |
|----|------------------|---|
| 1 | <i>Cardboard</i> |  |
| 2 | <i>Glass</i> |  |
| 3 | <i>Metal</i> |  |
| 4 | <i>Paper</i> |  |
| 5 | <i>Plastic</i> |  |
| 6 | <i>Others</i> |  |

B. Analisis Data

Gambar 1 merupakan alur analisis data, teknik pertama yang dilakukan yaitu dataset asli lalu dikonversi nilai pixel setiap gambar yang akan dibagi oleh 255, normalisasi piksel ke rentang antara 0 dan 1. Normalisasi pixel dapat membantu mempercepat konvergensi selama pelatihan. Selanjutnya, ukuran pixel gambar diubah menjadi 300x300 piksel untuk membantu menyederhanakan data dan semua gambar memulai model dengan ukuran yang sama, dikarenakan model *neural network* memiliki *layer* inputan dengan ukuran tetap.




Gambar 1. Alur analisis data

Kemudian gambar diaugmentasi dengan cara rotasi, pergeseran, *zoom*, dan pemutaran. Pada proses augmentasi rotasi digunakan untuk menghasilkan beberapa sudut pandang objek agar model lebih terlatih untuk mengenali objek dari berbagai orientasi, proses pergeseran difungsikan untuk membantu model agar lebih baik dalam mengenali objek yang mungkin tidak berada di tengah gambar. Proses *zoom* dapat membantu model untuk mengenali objek dari berbagai skala, dan proses pemutaran yang digunakan bila orientasi horizontal suatu objek tidak kritis untuk tugas klasifikasi. Alur analisis data yang terakhir yaitu pembagian data yang dibagi menjadi data latih, data validasi dan data uji.

C. Model Convolutional Neural Network (CNN)

Penelitian ini menggunakan algoritma CNN yang terbukti mampu untuk memproses data berupa inputan data gambar. Tujuan utama CNN yaitu mempelajari fitur-fitur dari data inputan. Tahapan awal yang dilakukan adalah mengekstraksi fitur konvolusional dengan filter yang akan menjadi lapisan awal. Filter yang diterapkan berfungsi sebagai jendela geser yang bergerak melintasi setiap filter data inputan. Dalam hal ini, jarak yang tumpang tindih disebut sebagai langkah, *output*-nya dikenal sebagai *feature maps*. Lalu, kernel konvolusional membentuk lapisan CNN yang digunakan untuk membuat *feature maps* yang berbeda. Untuk membuat *feature maps*, kernel harus dibagikan ke seluruh inputan lokasi spasial. Setelah konvolusional dan lapisan penyatuan telah dibuat, satu atau beberapa lapisan yang terhubung sepenuhnya digunakan untuk menyelesaikan klasifikasi [10].



Gambar 2. Arsitektur CNN

Gambar 2 merupakan arsitektur CNN dengan menerapkan beberapa filter pada suatu gambar yang akan dijalankan dengan menggunakan matriks tersebut [11]. Selama proses *training* pada penelitian ini menggunakan arsitektur CNN berupa *convolutional layer* yang menjalankan operasi konvolusi dengan mengubah inputan gambar menjadi *feature maps*. Perubahan tersebut dilakukan dengan operasi titik antara matriks inputan gambar dengan filter. Filter terdiri dari beberapa matriks bobot K yang disebut dengan kernel. Jumlah filter yang digunakan adalah *hyperparameter*. Jumlah filter menentukan jumlah *feature maps* yang dihasilkan. Jumlah kernel di *layer* ke l , sama dengan jumlah *feature maps* di *layer* ke $l - 1$. Berapa banyak filter yang digunakan di *layer* l dapat menentukan jumlah *feature maps* yang dihasilkan, dan jumlahnya sama dengan jumlah kernel pada *layer* $l + 1$. Berikut persamaan operasi konvolusional pada inputan *feature maps* ke q dapat dilihat seperti berikut:

$$S_q(g, h) = \left(\sum_{p=1}^P \sum_{u=1}^U \sum_{v=1}^U I_p(g + u, h + v) \cdot K_{pq}(u, v) \right) + b_g \quad (1)$$

dengan: $g = 0, 1, 2, \dots, G - 1$
 $h = 0, 1, 2, \dots, G - 1$
 $q = 0, 1, 2, \dots, Q$

dimana G adalah banyaknya kolom/baris pada *feature maps*. Sedangkan U adalah banyaknya kolom/baris pada kernel, Q adalah jumlah *feature maps* yang jumlahnya sama dengan jumlah filter. P adalah jumlah matriks kernel yang jumlahnya sama dengan matriks inputan.

$S_q(g, h)$: elemen *feature maps* ke- q
 $I_p(g + u, h + v)$: elemen matriks input ke- q
 $K_{pq}(u, v)$: elemen matriks kernel pq

b_g : bias pada filter ke- q [12].

Setelah menjalankan operasi *convolutional layers*, selanjutnya *pooling layers* pada arsitektur CNN lapisan ini melakukan pengambilan sampel ke bawah [13]. Tugas dari *layers* ini adalah mengurangi dimensi yang dikumpulkan dari *convolutional layers* dari setiap fitur agar mengurangi *overfitting* dan mempercepat komputasi. *Pooling layers* yang digunakan yaitu *max pooling layers* dan *average pooling layers* dengan ukuran 2×2 .

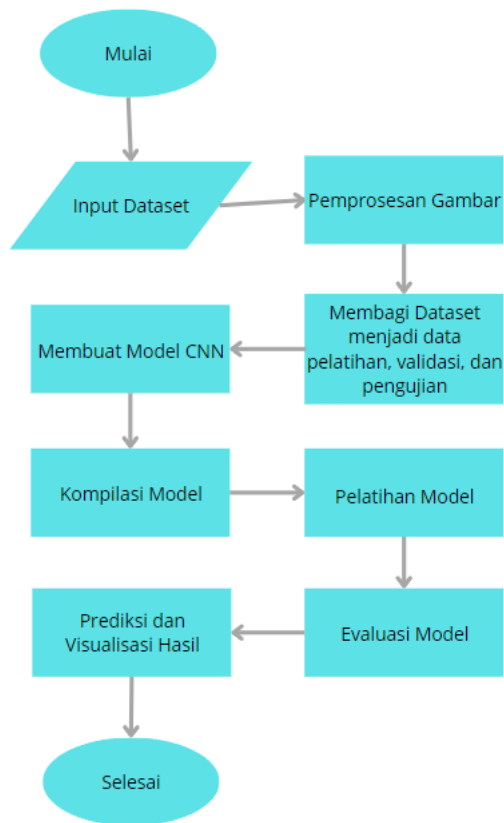
D. Implementasi Convolutional Neural Network (CNN)

Dalam membangun model CNN pada penelitian ini menggunakan *library* Keras yang biasa digunakan untuk membangun dan melatih model jaringan saraf tiruan. Beberapa *library* keras yang digunakan adalah `keras.preprocessing.image`, `keras.models`, `keras.layers`, `keras.optimizers`, `keras.preprocessing.image.ImageDataGenerator`.

Lapisan *Conv2D*, lapisan *MaxPooling2D*, lapisan *AveragePooling2D*, lapisan *Flatten* dan lapisan *Dense* berikut merupakan lapisan yang digunakan pada penelitian ini untuk membangun model CNN. Tahapan penggunaan algoritma CNN ditunjukkan pada Gambar 3.

E. Pengujian

Hasil yang didapatkan pada proses pengujian berupa nilai akurasi. Sedangkan, visualisasi gambar berupa prediksi yang diberikan oleh model dan label sebenarnya. Selain itu, ada pula grafik akurasi pelatihan dan validasi selama pelatihan model.



Gambar 3. Proses implementasi CNN

III. HASIL DAN PEMBAHASAN

Penelitian ini melakukan klasifikasi gambar menggunakan algoritma CNN. Dataset yang digunakan berupa gambar sampah yang terdiri dari 6 jenis sampah yaitu sampah *plastic*, *glass*, *metal*, *cardboard*, *paper*, dan *others*. Data pada penelitian ini dibagi menjadi tiga bagian yaitu data latih, data validasi dan data uji. Data latih digunakan untuk pelatihan model, data validasi digunakan untuk pelatihan dan mengukur kinerja model. Sedangkan data uji merupakan data digunakan untuk pengujian model. Ketika model berhasil dijalankan, maka hasil pengujian model akan menunjukkan nilai keberhasilan berupa nilai akurasi.

Dataset yang digunakan berupa dataset private dengan jumlah 1840 gambar. Setiap jenis memiliki jumlah gambar yang berbeda, jenis *plastic* (532), *glass* (239), *metal* (284), *cardboard* (315), *paper* (292), *others* (178). Selain itu, dataset diambil menggunakan kamera belakang *smartphone* dengan resolusi 13 MP. Jarak antara *smartphone* dan objek sampah sekitar 25-30 cm. Saat pengambilan gambar, kamera tegak lurus dengan objek dan menggunakan *background* putih.


A. Pengujian Epoch

Pada Tabel 2 dapat dilihat pembagian data latih dan data uji dapat mempengaruhi nilai akurasi. Pada penelitian ini menggunakan pembagian data 90/10, dikarenakan hasil akurasi dengan pembagian data 90/10 lebih tinggi dari pada perbandingan yang lainnya. Pembagian dataset gambar dibagi menjadi tiga yaitu 90% (1656 gambar) data latih, 2% (37 gambar) data validasi, dan 8% (147 gambar) data uji. Proporsi dataset sangat mempengaruhi untuk hasil akurasi. Selain itu, jumlah *epoch* untuk melatih model juga mempengaruhi hasil *training*.


Selain itu, jumlah *epoch* untuk melatih model juga mempengaruhi hasil *training*. Hasil *training dataset* 90/10 dengan 50 *epoch* dan 100 *epoch* berukuran *batch* 32 gambar per *training* berbeda, dapat dilihat pada Tabel 2 bahwa hasil akurasi dengan menggunakan 100 *epoch* lebih tinggi dibandingkan 50 *epoch*. Maka penelitian ini menggunakan *epoch* 100 agar mendapatkan hasil akurasi yang lebih baik. Pada Gambar 4 dan Gambar 5 merupakan grafik akurasi dan grafik *loss* menggunakan 100 *epoch*.

Tabel 2. Perbandingan hasil

| Data Latih/Data Uji | Epoch 50 | Epoch 100 |
|---------------------|----------|-----------|
| 70/30 | 69,88% | 73,56% |
| 80/20 | 74,32% | 77,56% |
| 90/10 | 78,33% | 81,08% |



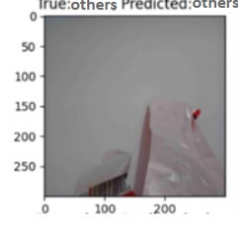
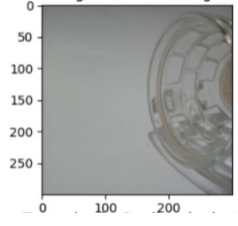

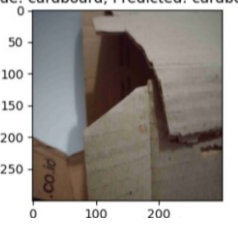
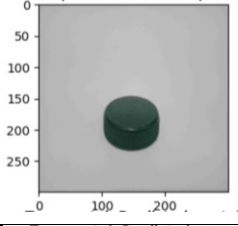
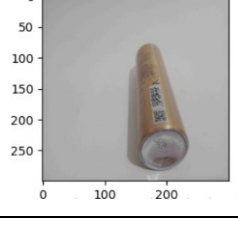
Gambar 4. Grafik akurasi

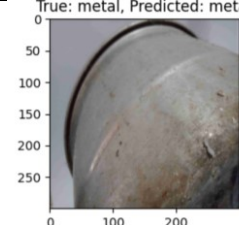
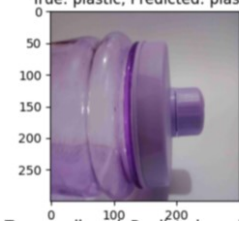
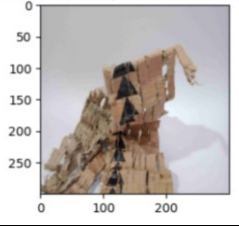
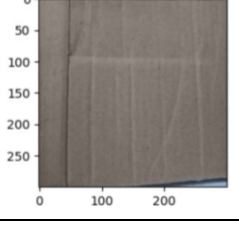
Gambar 5. Grafik *loss*

B. Prediksi Data

Pada Tabel 3 merupakan hasil prediksi dengan menggunakan 10 sampel gambar, dari total 37 gambar. Dapat dilihat bahwa hasil prediksi 10 gambar tersebut didapatkan 1 gambar yang salah prediksi.


Tabel 3. Hasil Prediksi

| Gambar Dataset | Tabel Sebenarnya | Tabel Prediksi |
|---|------------------|------------------|
|  | <i>others</i> | <i>others</i> |
|  | <i>glass</i> | <i>glass</i> |
|  | <i>cardboard</i> | <i>cardboard</i> |
|  | <i>cardboard</i> | <i>cardboard</i> |
|  | <i>plastic</i> | <i>plastic</i> |
|  | <i>metal</i> | <i>paper</i> |

| | | |
|---|------------------|------------------|
|  | <i>metal</i> | <i>metal</i> |
|  | <i>plastic</i> | <i>plastic</i> |
|  | <i>cardboard</i> | <i>cardboard</i> |
|  | <i>cardboard</i> | <i>cardboard</i> |

C. Hasil Klasifikasi

Hasil klasifikasi data *testing* ditampilkan dengan *confusion matrix* seperti pada Gambar 5.



Gambar 5. Confusion matrix

Tabel 4. *Confussion Matrix*

| Prediksi | Aktual | | | | | |
|-------------------|-------------------|--------------|--------------|--------------|----------------|---------------|
| | <i>Card board</i> | <i>Glass</i> | <i>Metal</i> | <i>Paper</i> | <i>Plastic</i> | <i>Others</i> |
| <i>Card board</i> | 3 | 0 | 0 | 0 | 0 | 0 |
| <i>Glass</i> | 0 | 8 | 0 | 0 | 0 | 0 |
| <i>Metal</i> | 1 | 0 | 9 | 1 | 1 | 0 |
| <i>Paper</i> | 0 | 0 | 0 | 0 | 1 | 1 |
| <i>Plastic</i> | 0 | 0 | 0 | 1 | 6 | 0 |
| <i>Others</i> | 0 | 0 | 0 | 0 | 1 | 4 |

Berdasarkan Gambar 5 dan Tabel 4 dapat dilihat bahwa hasil akurasi klasifikasi dari 37 gambar. Klasifikasi yang dilakukan menghasilkan nilai akurasi 85,45% untuk data latih, 81,08% data uji, dan 77,55% data validasi.

IV. KESIMPULAN

Sistem klasifikasi jenis sampah menggunakan algoritma CNN mampu dijalankan untuk mengidentifikasi jenis sampah dengan membuat model *convolutional layers*, *average pooling* dan *max pooling layers*. Selain itu, sistem klasifikasi citra jenis sampah menggunakan *input shape* 300 x 300, *learning rate* 0,001, *epochs* 100, data latih 1656, data validasi 37, dan data uji 147 dapat menghasilkan nilai akurasi 85,45% untuk data latih, 81,08% data uji, dan 77,55% data validasi. Berdasarkan penelitian yang telah dilakukan, masih banyak hal yang perlu dikembangkan agar memperoleh hasil yang lebih baik. Pada penelitian berikutnya diharapkan jumlah *dataset* dari setiap jenis bertambah agar hasil akurasi yang didapatkan lebih baik.

REFERENSI

- [1] Y. Novitasari, D. Prastyo, S. L. Ifitah, A. Reswari, and M. Fauziddin, "Media Daur Ulang (Recycle System) dalam Kemampuan Membaca Bahasa Inggris Awal Anak Usia Dini," *Jurnal Obsesi: Jurnal Pendidikan Anak Usia Dini*, vol. 6, no. 3, pp. 1323–1330, Sep. 2021.
- [2] Z. Nie, W. Duan, and X. Li, "Domestic garbage recognition and detection based on Faster R-CNN," *J Phys Conf Ser*, vol. 1738, no. 1, p. 012089, Jan. 2021.
- [3] L. Yan, X. Wang, and S. Yin, "Campus Garbage Image Classification Algorithm Based on New Attention Mechanism," *Int. J. Electron*, vol. 13, no. 4, pp. 131–141, 2021.
- [4] G. Alimjan, T. Sun, Y. Liang, H. Jumahun, and Y. Guan, "A New Technique for Remote Sensing Image Classification Based on Combinatorial Algorithm of SVM and KNN," *Int. J. Pattern Recognit. Artif. Intell.*, vol. 32, no. 7, 2018.
- [5] C. Tian, L. Fei, W. Zheng, Y. Xu, W. Zuo, and C. W. Lin, "Deep learning on image denoising: An overview," *Neural Netw.*, vol. 131, no. 83, pp. 251–275, 2020.
- [6] Z. Song, "English speech recognition based on deep learning with multiple features," *Computing*, vol. 102, pp. 663–682, 2020.
- [7] A. S. Nugroho, R. Umar, and A. Fadlil, "SISTEM PENGENALAN BOTOL PLASTIK BERDASARKAN LABEL MEREK MENGGUNAKAN FASTER-RCNN," *Jurnal Nasional UMP*, vol. 21, no. 2, pp. 111–118, 2020.
- [8] V. Seredkin, M. P. Tokarev, I. A. Plohih, O. A. Gobyzov, and D. M. Markovich, "Development of a method of detection and classification of waste objects on a conveyor for a robotic sorting system," in *Journal of Physics: Conference Series*, Institute of Physics Publishing, Nov. 2019.
- [9] N. Narayanswamy, A. R. Abdul Rajak, and S. Hasan, "Development of Computer Vision Algorithms for Multi-class Waste Segregation and Their Analysis," *Emerging Science Journal*, vol. 6, no. 3, pp. 631–646, Jun. 2022.
- [10] Q. Zhang, M. Zhang, T. Chen, Z. Sun, Y. Ma, and B. Yu, "Recent advances in convolutional neural network acceleration," *Neurocomputing*, vol. 323, pp. 37–51, 2019.
- [11] J. Xie, K. Hu, M. Zhu, J. Yu, and Q. Zhu, "Investigation of Different CNN -Based Models for Improved Bird Sound Classification," *IEEE Access*, vol. 7, pp. 175353–175361, 2019.
- [12] I. Wulandari, H. Yasin, and T. Widiharih, "KLASIFIKASI CITRA DIGITAL BUMBU DAN REMPAN DENGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)," *Jurnal Gaussian*, vol. 9, no. 3, pp. 273–282, 2020.
- [13] S. Loussaief and A. Abdelkrim, "Convolutional neural network hyper-parameters optimization based on genetic algorithms," *International Journal of Advanced Computer Science and Applications*, vol. 9, no. 10, pp. 252–266, 2018.

