

Identifying Types of Waste as Efforts in Plastic Waste Management Based on Deep Learning

Identifikasi Jenis Sampah sebagai Upaya Pengolahan Limbah Plastik berbasis Deep Learning

Irawadi Buyung¹, Agus Qomaruddin Munir², Nurhadi Wijaya S.³, Latifah Listyalina⁴

¹ Teknik Elektro, Universitas Respati Yogyakarta, Indonesia

² Teknologi Informasi, Universitas Respati Yogyakarta, Indonesia

³ Informatika, Universitas Respati Yogyakarta, Indonesia

^{4*} Teknologi Pengolahan Karet dan Plastik, Politeknik ATK Yogyakarta, Indonesia

¹buyungirawadi@gmail.com, ²agusqmnr@respati.ac.id, ³nurhadi@respati.ac.id,

^{4*}latifah.listyalina@atk.ac.id

*: *Penulis korespondensi (corresponding author)*

Informasi Artikel

Received: September 2023

Revised: September 2023

Accepted: October 2023

Published: October 2023

Abstract

Purpose: This research aims at designing a computer algorithm for automatic waste sorting.

Design/methodology/approach: This research is quantitative and uses secondary data, specifically images of various types of waste. The images will be classified into organic and inorganic waste types with the assistance of a deep learning model. In this research, we propose the EfficientNet method for Waste Type Identification as an Effort in Plastic Waste Management. Experiments were conducted on a secondary dataset from Kaggle.com, which involved classifying various types of waste into "Plastic" and "Non-Plastic" categories, showing the effectiveness of the proposed method.

Findings/result: The measurement is performed to compute the accuracy of the designed deep learning model in classifying waste images into the appropriate waste types. Based on the research results, our system achieved the highest accuracy of 97% during testing.

Originality/value/state of the art: The designed method can perform fast and automatic waste sorting, which is useful in reducing the increasing amount of waste accumulating each year.

Abstrak

Tujuan: Penelitian ini bertujuan untuk merancang algoritma komputer untuk pengelompokan limbah secara otomatis.

Perancangan/metode/pendekatan: Penelitian ini bersifat kuantitatif dan menggunakan data sekunder, khususnya gambar berbagai jenis limbah. Gambar-gambar tersebut

Keywords: deep learning; waste; identification;

Kata kunci: deep learning; sampah; identifikasi

akan diklasifikasikan menjadi jenis limbah organik dan anorganik dengan bantuan model pembelajaran mendalam. Dalam penelitian ini, kami mengusulkan metode EfficientNet untuk Identifikasi Jenis Limbah sebagai Upaya dalam Pengelolaan Limbah Plastik. Eksperimen dilakukan pada dataset sekunder dari Kaggle.com, yang melibatkan klasifikasi berbagai jenis limbah menjadi kategori "Plastik" dan "Non-Plastik", menunjukkan efektivitas metode yang diusulkan.

Hasil: Pengukuran dilakukan untuk menghitung akurasi model pembelajaran mendalam yang dirancang dalam mengklasifikasikan gambar limbah ke dalam jenis limbah yang sesuai. Berdasarkan hasil penelitian, sistem kami mencapai akurasi tertinggi sebesar 97% selama pengujian.

Keaslian/*state of the art*: Metode yang dirancang dapat melakukan pengelompokan limbah secara cepat dan otomatis, yang berguna dalam mengurangi jumlah limbah yang terus meningkat setiap tahun.

1. Pendahuluan

Sampah adalah zat sisa yang sudah tidak terpakai dan dibuang yang dihasilkan dari suatu proses produksi domestik (rumah tangga) atau industri. Jumlah timbunan sampah di Indonesia dalam setahun sekitar 67,8 juta ton, jumlah itu akan terus bertambah seiring dengan pertumbuhan jumlah penduduk di Indonesia. Hal ini membuat Tempat Penampungan Akhir (TPA) penuh karena tumpukan sampah yang berlebih yang dapat membuat kerusakan di lingkungan sekitar. Jenis sampah yang paling banyak dihasilkan di Indonesia adalah sampah organik sebanyak 60%, sampah plastik 14%, sampah kertas 9%, kaca, kayu dan bahan lainnya 12,7%. [1], [2]

Seperti yang telah diketahui, sampah sudah menjadi masalah bagi semua lapisan masyarakat. Semakin hari sampah semakin menumpuk, perbandingan antara jumlah sampah yang dihasilkan dengan sampah yang diolah tidak seimbang. Penumpukan sampah yang tidak sesuai dengan kapasitas adalah permasalahan yang nyata. Salah satu penyebab penumpukan sampah adalah proses pengelolaan sampah yang tidak sebanding kecepatannya dengan jumlah sampah yang menumpuk per-harinya. Salah satu proses pengelolaan sampah yang sering menjadi kendala adalah pemilahan sampah [3], [4]. Hasil wawancara pada [5] yang menjadi kendala ketika melakukan pengelolaan sampah adalah pemilahan sampah terutama dengan sampah organik karena faktor bau. Sampah organik dan anorganik memiliki lama penguraian yang berbeda. Sampah organik memiliki waktu yang lebih cepat dibandingkan dengan sampah anorganik. Oleh sebab itu sampah organik dan anorganik memiliki cara penanganan daur ulang yang berbeda pula. Pemilahan sampah sebelum ditampung ke Tempat Pemungutan Akhir (TPA) sangat penting untuk mengurangi jumlah penimbunan sampah yang terus meningkat setiap tahunnya.

Permasalahan ini dapat ditangani dengan mengimplementasikan mesin yang dapat memilah sampah dengan otomatis. Mesin tidak akan menghiraukan bau sampah namun dapat dengan efektif memilah sampah. Mesin harus memiliki sistem yang mampu mengidentifikasi jenis sampah. Berdasarkan permasalahan yang terjadi, diperlukan penelitian mengenai identifikasi sampah secara otomatis sehingga menjadi upaya penyelamatan bumi dengan manajemen pengolahan sampah [6], [7].

Pemisahan jenis sampah merupakan tahapan awal sebelum dari proses daur ulang dilakukan. Penginderaan jenis dan bentuk sampah dengan kamera adalah satu metode yang menantang dalam penelitian di bidang computer vision. Dengan menggunakan metode ini dapat membuat sistem pemilahan sampah yang otomatis. Hasil penelitian menunjukkan bahwa model CNN yang paling baik adalah Resnet 50. Nilai akurasi yang didapatkan dari train adalah 78% dan 90%. Sedangkan nilai akurasi dari validation sebesar 74% dan 80%. Dalam penelitian ini untuk dapat menerapkan teknologi pemisahan sampah secara otomatis pada tempat sampah maka dapat menggunakan model Resnet 50 apabila menggunakan server atau komputer dengan spesifikasi yang tinggi [8].

Sampah plastik merupakan hasil kebutuhan manusia akan produk berbahan dasar plastik. Karena kebutuhan yang tinggi, pembuatan dan penggunaan plastik sebagai bahan baku yang diproduksi tidak menggunakan plastik sebagai bahan baku pembuatannya. Untuk dapat melakukan pemilahan dan penyaringan sampah plastik dengan lebih baik, dibutuhkan tenaga manusia [9], [10]. Hal ini menyebabkan manusia memiliki kemampuan untuk mengurutkan dan memfilter objek visual, tetapi manusia memilikinya kurang konsisten dalam berbagai faktor yang mempengaruhi. Namun, jika diterapkan pada sistem komputasi, sampah plastic sistem pengobatan akan memberikan hasil yang konsisten. Berdasarkan hasil pengujian dan evaluasi yang telah dilakukan selama penelitian, maka dapat diperoleh kesimpulan sebagai berikut. Sampah plastik dapat dipisahkan menggunakan Deep Learning dengan mengenali citra dan pola dari gambar yang diproses. Sampah plastik di pisahkan dalam 7 kategori dan memiliki kode pada kemasan. Model Deep Learning dapat diinstall ke dalam aplikasi atau sistem terpasang dalam manufaktur pengolahan sampah [11], [12].


Dari [13] 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. 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.

Di berbagai negara sampah merupakan permasalahan yang dihadapi sehari-hari seluruh aktivitas tidakbisa terhindar dari kata sampah [14]. Oleh karena itu Sistem Klasifikasi Limbah Pada Web Service Berbasis Framework Flask akan sangat membantu masyarakat dalam mengklasifikasikan limbah sampah yang dihasilkan. Sistem klasifikasi limbah pada aplikasi berbasis web ini menggunakan metode Convolutional Neural Network (CNN). Metode CNN merupakan suatu metode deep learning yang dapat mengidentifikasi dan mengklasifikasi sebuah object pada citra digital. Penelitian ini menggunakan arsitektur VGGNet. Dataset yang digunakan yaitu 8371 citra limbah sampah. Dimana dataset tersebutdigunakan untuk melakukan trainingdata yang telah dibagi menjadi 1.122 citra battery, 729 pakaian, 624 e-limbah, 773 kaca, 651 bola lampu, 1092 metal, 671 organic, 1468 kertas dan1241 plastic. Pada proses training, dilakukan sebanyak 28 epoch, yang mendapatkan akurasi tertinggi 69,77% dengan loss terendah 0,34. Untuk data testing, didapatkan hasil 64,45% accuracy [15].

2. Metode/Perancangan

Konsep penelitian mempunyai beberapa variabel, yaitu variabel independen (variabel bebas) dan variabel dependen (variabel terikat). Variabel bebas pada penelitian ini adalah citra keseluruhan jenis sampah sedangkan variabel terikat adalah hasil klasifikasi jenis sampah

pada set pengujian oleh algoritma yang dirancang. Untuk lebih jelasnya, kerangka konsep penelitian dapat dilihat pada Gambar 1.



Gambar 1. Kerangka Konsep Penelitian

Penelitian ini berjenis kuantitatif dan menggunakan data sekunder, yakni data citra jenis-jenis sampah yang diunduh dari <https://www.kaggle.com/datasets/aashidutt3/waste-segregation-image-dataset>.

Citra akan diklasifikasikan ke jenis sampah organik dan sampah anorganik dengan bantuan model *deep learning*. Pengukuran yang dilakukan berupa pengukuran tingkat akurasi model *deep learning* yang dirancang dalam mengklasifikasikan citra sampah ke jenis-jenis sampah yang sesuai. Ukuran setiap citra pada dataset tersebut berukuran yang berbeda-beda dengan format JPG dan PNG. Masing-masing citra dilengkapi dengan label jenis sampahnya. Label ini membedakan sampah organik dan anorganik.

telah dibagi beberapa tahapan penelitian ini. Tahap pertama dilakukan dengan peninjauan teori dan pustaka yang terkait dengan penelitian ini. Teori yang dimaksud ialah dasar-dasar teori yang terkait pada penelitian ini, seperti hal-hal terkait sampah ataupun deep learning sedangkan pustaka yang dimaksud adalah beberapa penelitian terdahulu yang terkait dengan penelitian di mana akan menjadi masukan dan dasar dalam melakukan penelitian.

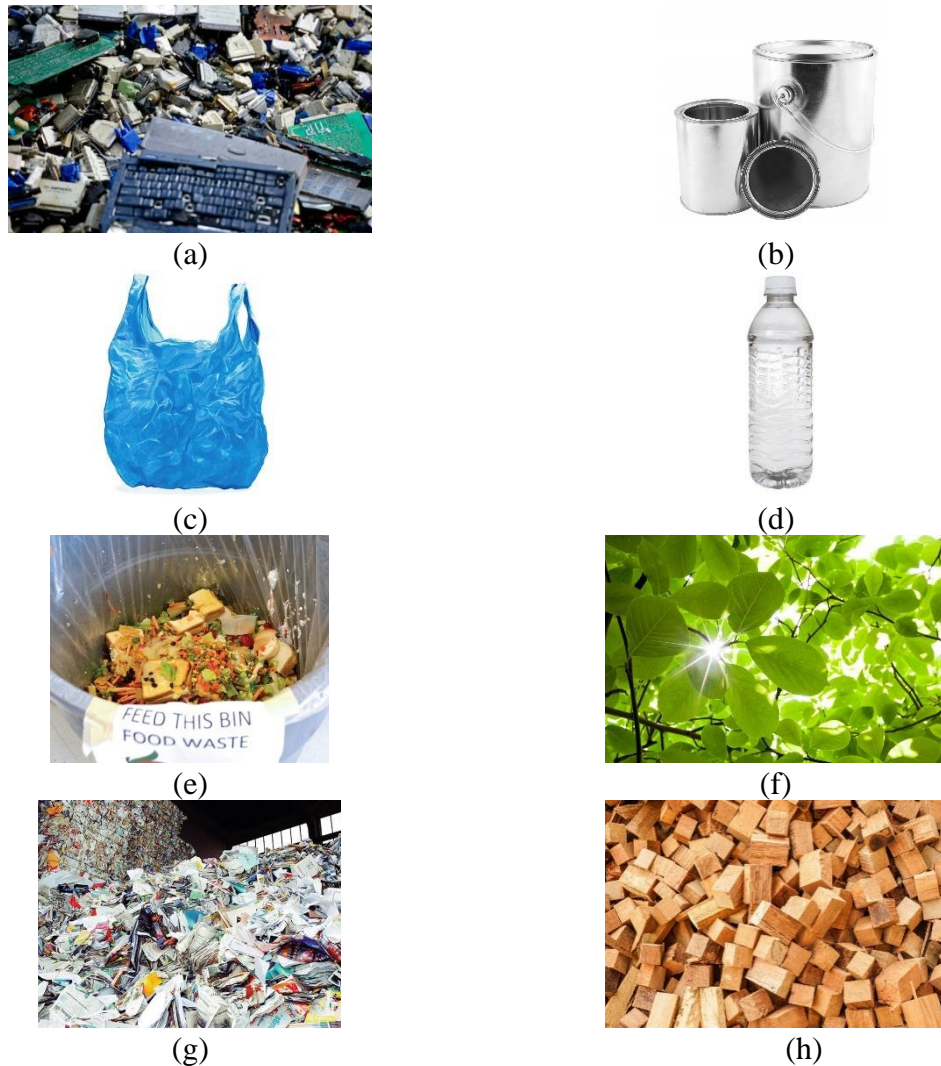
Tahap kedua adalah tahapan dalam menentukan data dan metode penelitian. Penentuan ini disesuaikan dengan judul yang telah diusung, seperti data yang dibutuhkan ialah data sampah yang sudah diklasifikasikan menurut kebutuhan penelitian ini di mana data tersebut tersedia dalam dataset sekunder Kaggle.com. Untuk metode penelitian, akan disesuaikan metode deep learning yang mampu mengidentifikasi kelas yang dibutuhkan.

Tahap ketiga dan tahap keempat ialah mengaplikasikan metode deep learning yang telah dipilih dari hasil tahap kedua. Keberhasilan pelatihan metode akan menentukan keberhasilan pengujian yang akan digunakan. Hal tersebut akan bergantung pada koefisien-koefisien yang akan dipilih pada proses pelatihan. Setelah proses pengujian selesai, tahap kelima merupakan proses penilaian performa hasil pengujian sebelumnya. Hasil kuantitatif tahapan ini menentukan keberhasilan penelitian ini. Baik tidaknya nilai performa penelitian akan menentukan proses publikasi yang ada pada tahap keenam.

Tahap terakhir penelitian ini atau tahap ketujuh ini akan membahas mengenai penulisan laporan di mana laporan di sini disertai persiapan lampiran laporan. Laporan di sini berisi mengenai pembahasan penelitian yang telah dilalui beserta hasil akhir penelitian. Hal tersebut dimulai dari pembahasan data, metode, pelatihan, pengujian, dan performa penelitian.

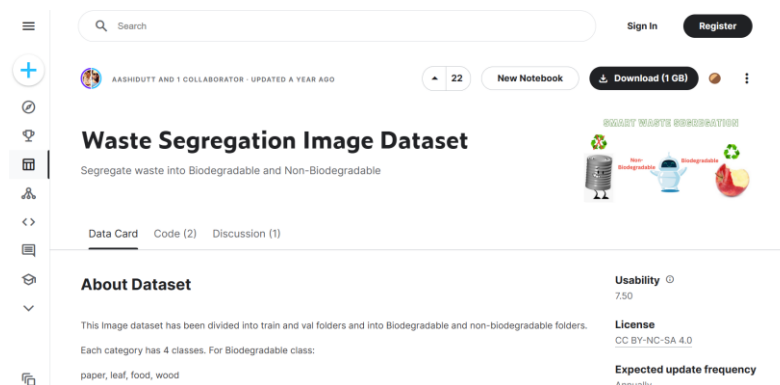
3. Hasil dan Pembahasan

Penelitian ini membutuhkan dataset sebagai bahan penelitian. Dataset pada penelitian telah diunduh dari <https://www.kaggle.com/datasets/aashidutt3/waste-segregation-image-dataset>. Berikut contoh-contoh data yang akan digunakan.



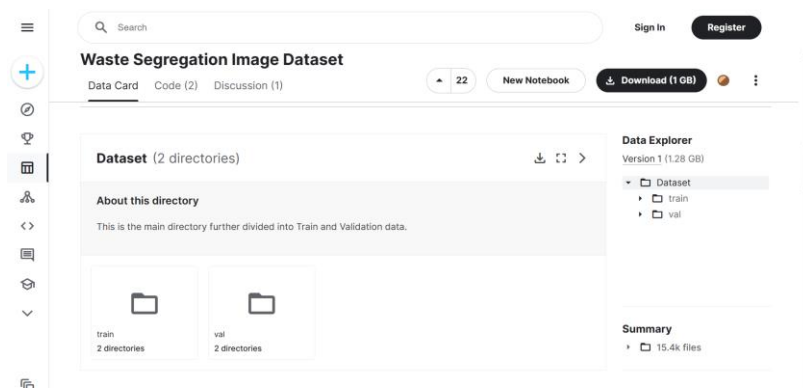
Gambar 2. Contoh dataset sampah yang digunakan (a) elektronik (b) metal (c) plastik (d) botol (e) makanan (f) daun (g) kertas (h) kayu (Kaggle.com)

Adapun tampilan situs dari dataset sebagai berikut.



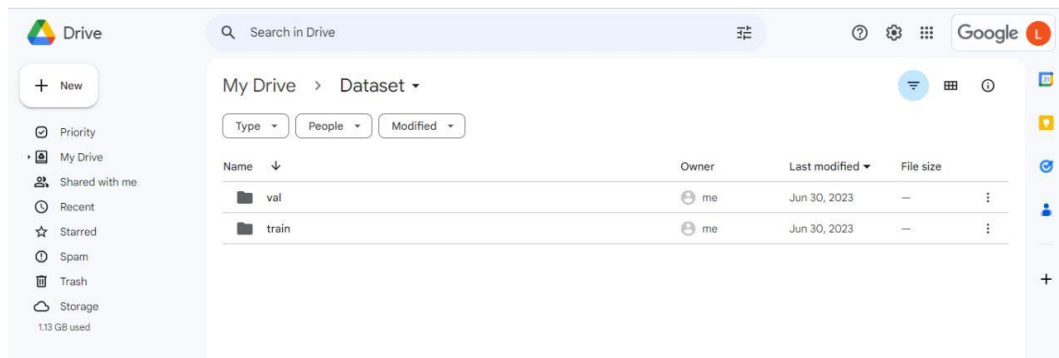
Gambar 3. Tampilan Situs Dataset

Pada dataset tersebut, dikelaskan menjadi data pelatihan dan data pengujian. Hal tersebut sesuai dengan Gambar 3 di mana masing-masing kelas tersebut terbagi menjadi berbagai macam sampah, seperti sampah yang dapat terurai secara alami dan sampah yang tidak dapat terurai secara alami.



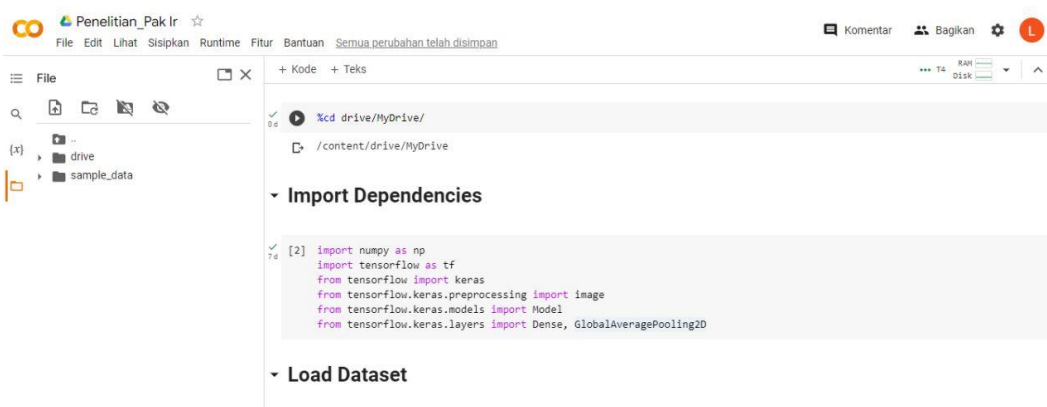
Gambar 4. Tampilan Macam Sampah

Dari keseluruhan data di atas, telah dilakukan pengunduhan. Kemudian dilakukan pula penyimpanan data hasil pengunduhan pada GoogleDrive. Hal tersebut dilakukan untuk mempermudah pemanggilan direktori Ketika proses pelatihan dan pengujian. Adapun hal yang dimaksud di atas dipaparkan sebagai berikut.



Gambar 5. Hasil Penyimpanan Data di GoogleDrive

Selanjutnya, dilakukan perancangan algoritma dengan bantuan Phyton dan Google Colab yang dapat ditunjukkan pada Gambar 5.



Gambar 6. Perancangan Algoritma

Setelah dirancang dan ditentukan algoritma yang akan digunakan, akan dilakukan pemanggilan dataset sesuai dengan direktori yang ada di GoogleDrive. Setelah dilakukan proses ini, pelatihan dan pengujian baru dapat dilakukan. Adapun proses pemanggilan dataset ditunjukkan pada Gambar 6.

Load Dataset

```
[3] train_ds_non_biodegradable = tf.keras.utils.image_dataset_from_directory(
    './Dataset/train/non_biodegradable/',
    labels="inferred",
    label_mode="int",
    color_mode="rgb",
    batch_size=32,
    image_size=(256, 256),
    seed=None,
    validation_split=None,
    subset=None,
    interpolation="bilinear",
    follow_links=False,
    crop_to_aspect_ratio=False,
)

train_ds_biodegradable = tf.keras.utils.image_dataset_from_directory(
    './Dataset/train/biodegradable/',
    labels="inferred",
    label_mode="int",
    color_mode="rgb",
    batch_size=32,
    image_size=(256, 256),
    seed=None,
```

Gambar 7. Pemanggilan Dataset

Selanjutnya dilakukan proses pemanggilan dataset dengan menambahkan proses augmentasi di mana augmentasi data merupakan proses memodifikasi atau memanipulasi suatu citra, sehingga citra asli dalam bentuk standar akan diubah bentuk dan posisinya. Langkah ini bertujuan agar komputer dapat belajar dan mengenali dari berbagai data yang berbeda-beda sekaligus bisa dimanfaatkan untuk memperbanyak data. Hal tersebut digambarkan pada Gambar 7.

```
[3] data_augmentation = keras.Sequential(
    [
        tf.keras.layers.RandomFlip("horizontal",
            input_shape=(256, 256, 3)),
        tf.keras.layers.RandomRotation(0.3),
        tf.keras.layers.RandomZoom(0.3),
    ]
)

def merge_label_non_bio(labels):
    labels = labels>1
    return tf.convert_to_tensor(tf.cast(labels, tf.int16))

def merge_label_bio(labels):
    labels = labels>100
    return tf.convert_to_tensor(tf.cast(labels, tf.int16))

train_ds_non_biodegradable = train_ds_non_biodegradable.map(lambda x, y: (data_augmentation(x), merge_label_non_bio(y)),
    num_parallel_calls=tf.data.AUTOTUNE)

train_ds_biodegradable = train_ds_biodegradable.map(lambda x, y: (data_augmentation(x), merge_label_bio(y)),
    num_parallel_calls=tf.data.AUTOTUNE)

train_ds = train_ds_non_biodegradable.concatenate(train_ds_biodegradable)

val_ds_non_biodegradable = tf.keras.utils.image_dataset_from_directory(
```

Gambar 8. Proses Pemanggilan dan Augmentasi Data

Selanjutnya, akan dilakukan proses pendefinisian model EfficientNet-B0 di mana EfficientNet termasuk salah satu teknik transfer learning yang dikhususkan untuk masalah pengenalan objek atau klasifikasi gambar. Hal tersebut sesuai dengan tujuan penelitian ini, yaitu melakukan klasifikasi sampah berdasarkan gambarnya. Adapun proses yang dimaksud dipaparkan pada Gambar 8.

Build Model

```
inputs = tf.keras.Input(shape=(256, 256, 3))

base_model = tf.keras.applications.efficientnet.EfficientNetB0(
    include_top=False,
    weights='imagenet'
)

# add a global spatial average pooling layer
x = base_model(inputs)
x = tf.keras.layers.Dropout(0.3)(x)
x = GlobalAveragePooling2D()(x)
# let's add a fully-connected layer
x = Dense(1024, activation='relu')(x)
# and a logistic layer -- let's say we have 200 classes
predictions = Dense(1)(x)

# this is the model we will train
model = Model(inputs=inputs, outputs=predictions)

model.compile(optimizer=keras.optimizers.legacy.Adam(learning_rate = 0.0001),
              loss=tf.keras.losses.BinaryCrossentropy(from_logits=True),
              metrics = [keras.metrics.AUC(from_logits=True, name='auc')])
```

Gambar 9. Proses Pendefinisian Model Algoritma

Langkah selanjutnya yaitu proses pelatihan data sebanyak 50 epoch menggunakan model algoritma yang telah dipilih sebelumnya seperti ditunjukkan pada Gambar 9.

```
model.fit(train_ds, epochs = 50)

model.save_weights("best_weight.npy")

Epoch 20/50
280/280 [=====] - 184s 650ms/step - loss: 0.0083 - auc: 0.9991
Epoch 21/50
280/280 [=====] - 183s 645ms/step - loss: 0.0019 - auc: 1.0000
Epoch 22/50
280/280 [=====] - 184s 648ms/step - loss: 0.0024 - auc: 1.0000
Epoch 23/50
280/280 [=====] - 184s 648ms/step - loss: 0.0015 - auc: 1.0000
Epoch 24/50
280/280 [=====] - 182s 643ms/step - loss: 0.0013 - auc: 1.0000
Epoch 25/50
280/280 [=====] - 185s 646ms/step - loss: 0.0023 - auc: 1.0000
Epoch 26/50
280/280 [=====] - 182s 644ms/step - loss: 0.0031 - auc: 1.0000
Epoch 27/50
280/280 [=====] - 183s 643ms/step - loss: 0.0038 - auc: 0.9991
Epoch 28/50
280/280 [=====] - 183s 644ms/step - loss: 0.0030 - auc: 0.9992
Epoch 29/50
280/280 [=====] - 183s 644ms/step - loss: 0.0022 - auc: 1.0000
Epoch 30/50
280/280 [=====] - 184s 645ms/step - loss: 0.0029 - auc: 1.0000
Epoch 31/50
```

Gambar 10. Proses Pelatihan Data dengan 50 Epoch

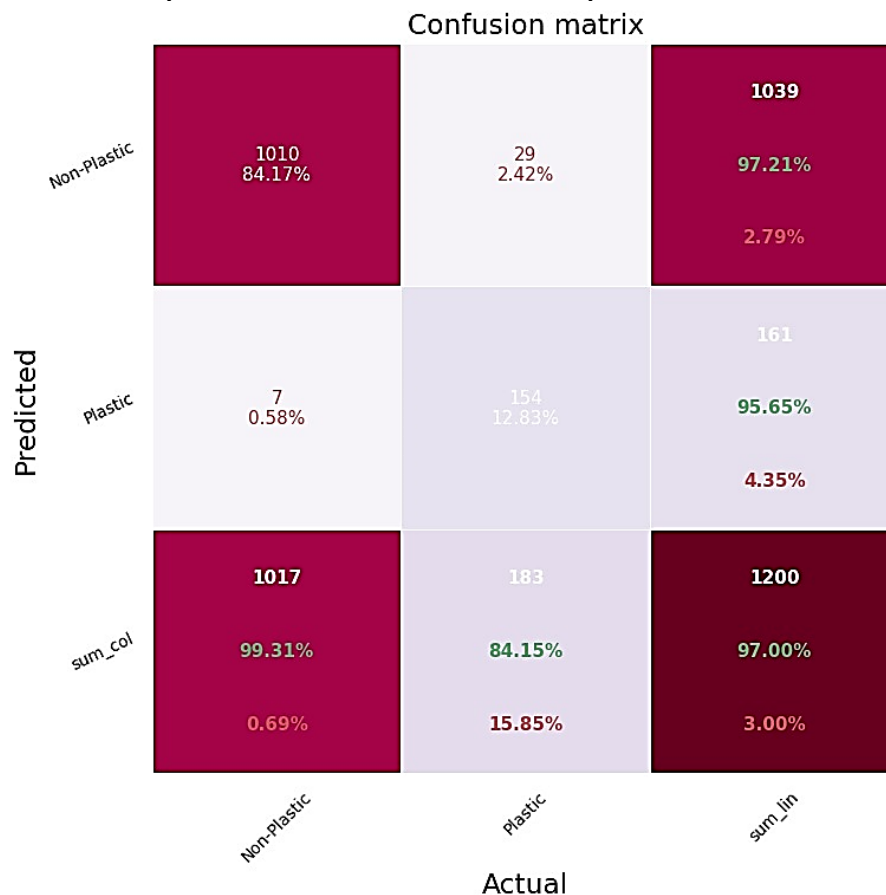
Langkah selanjutnya yang belum dilakukan ialah finalisasi proses pelatihan data dengan nilai performa yang terbaik sebab nilai tersebut akan menjadi dasar proses pengujian data penelitian. Setelah diperoleh hasil pelatihan yang terbaik, akan dilakukan proses pengujian data sehingga akan dihasilkan penelitian yang komprehensif.

Dari hasil pelatihan data seperti yang ditunjukkan Gambar 9, dilakukan proses pengujian. Adapaun proses tersebut telah dihitung performanya dan ditunjukkan pada Tabel 1 berikut.

Tabel 1. Performa Pengujian

Label	Presisi	Recall	F1-Score	Support
0	0.97	0.99	0.98	1017
1	0.96	0.84	0.90	183
Accuracy	0.97			1200
Macro avg	0.96			1200
Weighted avg	0.97	0.97	0.97	1200

Dari Tabel 1 di atas, diperoleh nilai confusion matrix seperti oada Gambar 10 di bawah ini.



Gambar 11. Confusion Matriks Hasil Pengujian

4. Kesimpulan dan Saran

Dalam penelitian ini, kami mengusulkan metode EfficientNet untuk Identifikasi Jenis Sampah sebagai Upaya Pengolahan Limbah Plastik. Eksperimen yang dilakukan pada dataset sekunder dari Kaggle.com, yang melibatkan klasifikasi macam-macam sampah ke dalam kategori "Plastik" dan "Non-Plastik", menunjukkan keefektifan metode yang diusulkan. Berdasarkan hasil penelitian, sistem kami mencapai akurasi terbaik sebesar 97% selama pengujian. Temuan ini menunjukkan bahwa deep learning, dikombinasikan dengan teknik klasifikasi yang dapat dijelaskan, menjanjikan klasifikasi sampah. Kemampuan untuk mencapai tingkat akurasi yang tinggi dengan akurasi 97%, menggarisbawahi potensi kegunaan klinis dari pendekatan kami. Klasifikasi sampah sangat penting untuk salah satu

alat bantu awal dalam pemilahan sampah seperti anjuran pemerintah dan kinerja metode kami yang kuat menunjukkan relevansinya untuk aplikasi dunia nyata dalam bidang limbah sampah.

Daftar Pustaka

- [1] A. T. Setiawan, "Identifikasi Jenis Sampah Secara Otomatis Menggunakan Metode Convolutional Neural Network (CNN)," *Smart Comp*, vol. 11, no. 2, 2022.
- [2] V. K. A. Md Zahangir Alom, Tarek M. Taha, Christopher Yakopcic, Stefan Westberg, Paheding Sidike, Mst Shamima Nasrin, Brian C Van Esesn, Abdul A S. Awwal, "The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches," *Comput. Vis. Pattern Recognit.*, 2018.
- [3] A. Dinda Clasissa Aulia, Harry Kiswanto Situmorang, Ahmad Fauzy Habiby Prasetya, Adhe Fadilla, I. Safira Nisa, Asiyah Khoirunnisa, Deo Farhan, Dwi Nur'aini Nindya, Hanisa Purwantari, R. F. L. Octaviani Dwi Jasmin, Johninda Aulia Akbar, Novi Mesrina Cicionta BR Ginting, and Z. P. G, "Peningkatan Pengetahuan dan Kesadaran Masyarakat tentang Pengelolaan Sampah dengan Pesan Jepang," *J. Pengabd. Kesehat. Masy.*, vol. 1, no. 1, 2021.
- [4] L. et al Listyalina, "Deep-RIC: Plastic Waste Classification using Deep Learning and Resin Identification Codes (RIC).," *Telemat. J. Inform. dan Teknol. Inf.*, vol. 19, no. 2, pp. 215–228, 2022.
- [5] D. Fahmi, "Pemilahan Sampah Menggunakan Model Klasifikasi Support Vector Machine Gabungan dengan Convolutional Neural Network," *JURIKOM (Jurnal Ris. Komputer)*, vol. 10, no. 1, 2023.
- [6] W. Budiharto, *Machine Learning & Computational Intelligence, Indonesia*. 2016.
- [7] A. C. Malina, Suhasman, A. Muchtar, and Sulfahri, "KAJIAN LINGKUNGAN TEMPAT PEMILAHAN SAMPAH DI KOTA MAKASSAR," *J. Inov. dan Pelayanan Publik Makassar*, vol. 1, no. 1, 2017.
- [8] H. S. Stephen Stephen, Raymond Raymond, "Applikasi Convolution Neural Network Untuk Mendeteksi Jenis-jenis Sampah," *Explor. J. Sist. Inf. dan Telemat.*, 2019.
- [9] Y. Kusnaedi, "Eksplorasi Sampah Plastik Menggunakan Metode 'Heating' Untuk Produk Pakai," in *Seminar Nasional Itenas*, 2018, pp. 11–21.
- [10] M. I. Utami and dan D. E. A. F. Ningrum, "Proses Pengolahan Sampah Plastik di UD Nialdho Plastik Kota Madiun," *Indones. J. Conserv.*, vol. 9, no. 2, pp. 89–95, 2020.
- [11] Hendri dkk, "Penerapan Machine Learning Untuk Mengategorikan Sampah Plastik Rumah Tangga," *J. STMIK*, vol. X, no. 2, 2022.
- [12] L. et al. Listyalina, "Conv-Tire: Tire Condition Assessment using Convolutional Neural Networks," *Telemat. J. Inform. dan Teknol. Inf.*, vol. 19, no. 3, pp. 323–336, 2022.
- [13] dkk. Kohsasih, "Analisis Perbandingan Algoritma Convolutional Neural Network Dan Algoritma Multi-Layer Perceptron Neural Dalam Klasifikasi Citra Sampah," *J. TIMES*, vol. X, no. 2, 2022.
- [14] I. G. M. A. I Made Pageh, "Solusi Strategis Penangan Masalah Sampah Dengan Mengolah Sampah Dapur Menjadi Pupuk Organik Cair (POC): (Kasus Dua Desa

- Pinggir Kota di Kota Singaraja Bali,” *J. Ilm. Ilmu Sos.*, vol. 4, no. 2, pp. 175–180, 2018.
- [15] Dacipta, “Sistem Klasifikasi Limbah Menggunakan Metode Convolutional Neural Network (CNN) Pada Web Service Berbasis Framework Flask,” *JINACS (Journal Informatics Comput. Sci.)*, vol. 3, no. 4, 2022.