

B3 Waste Image - Based Classification Using the VGG16 Convolutional Neural Network Model

[Klasifikasi Limbah B3 Berbasis Citra Menggunakan Model Convolutional Neural Network VGG16]

Wahyu Ismanda¹⁾, Suprianto ^{*,2)} Nuril Lutvi Azizah ^{*,3)} Mochamad Alfian Rosid ^{*,4)}

¹⁾Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

²⁾ Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

³⁾ Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

⁴⁾ Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

Email Penulis : 191080200120@umsida.ac.id, nurillutviazizah@umsida.ac.id, alfianrosid@umsida.ac.id

*Email Penulis Korespondensi: suprianto@umsida.ac.id

Abstract Hazardous and Toxic Waste (B3 waste) has characteristics that can pose risks to human health and the environment if it is not properly identified and managed. Manual classification has limitations because it depends on human ability and may result in errors when distinguishing objects with similar visual characteristics. This study aims to apply a Convolutional Neural Network (CNN) using the VGG16 architecture with a transfer learning approach to classify images of B3 waste. The dataset was independently collected through Roboflow and consisted of seven classes: batteries, battery packs, light bulbs, oil and thinner bottles, aerosol spray cans, electronic waste, and metal. The images were resized to 224×224 pixels and subjected to normalization and augmentation during the training process. The VGG16 model used ImageNet pretrained weights with the base layers frozen and an additional classification layer adapted to the seven classes. The model was trained using the Adam optimizer with a learning rate of 0.001 and categorical crossentropy loss. Model evaluation was performed using accuracy, precision, recall, F1-score, and a confusion matrix. Testing on 880 images resulted in an accuracy of 77% and an average F1-score of 0.77. The best performance was achieved by the oil and thinner bottle class with an F1-score of 0.93, while the lowest performance was obtained by the aerosol spray can class with an F1-score of 0.57. The results indicate that VGG16 can be applied to B3 waste image classification, although improvements in dataset quality and diversity are still required to enhance model performance.

Keywords – B3 waste, image classification, Convolutional Neural Network, VGG16, transfer learning

Abstrak Limbah Bahan Berbahaya dan Beracun (B3) memiliki karakteristik yang dapat membahayakan kesehatan manusia dan lingkungan apabila tidak diidentifikasi dan dikelola dengan tepat. Proses klasifikasi yang masih dilakukan secara manual memiliki keterbatasan karena bergantung pada kemampuan manusia dan dapat mengalami kesalahan dalam membedakan objek yang memiliki kemiripan visual. Penelitian ini bertujuan menerapkan *Convolutional Neural Network* (CNN) dengan arsitektur VGG16 menggunakan pendekatan *transfer learning* untuk mengklasifikasikan citra limbah B3. Dataset diperoleh secara mandiri melalui Roboflow dan terdiri atas tujuh kelas, yaitu aki, baterai, bola lampu, botol minyak dan thinner, kaleng semprot aerosol, limbah elektronik, dan logam. Citra diubah ukurannya menjadi 224×224 piksel dan dilakukan normalisasi serta augmentasi pada data latih. Model VGG16 menggunakan bobot ImageNet dengan lapisan dasar yang dibekukan dan lapisan klasifikasi yang disesuaikan dengan tujuh kelas. Pelatihan menggunakan optimizer Adam dengan *learning rate* 0,001 dan fungsi *categorical crossentropy*. Evaluasi dilakukan menggunakan *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Hasil pengujian terhadap 880 citra menghasilkan *accuracy* sebesar 77% dan *F1-score* rata-rata sebesar 0,77. Performa terbaik diperoleh pada kelas botol minyak dan thinner dengan *F1-score* sebesar 0,93, sedangkan performa terendah terdapat pada kelas kaleng semprot aerosol dengan *F1-score* sebesar 0,57. Hasil penelitian menunjukkan bahwa VGG16 dapat digunakan untuk klasifikasi citra limbah B3, meskipun peningkatan kualitas dan keragaman dataset masih diperlukan untuk meningkatkan performa model.

Kata Kunci - Limbah B3, klasifikasi citra, Convolutional Neural Network, VGG16, transfer learning

I. PENDAHULUAN

Limbah Bahan Berbahaya dan Beracun (B3) merupakan salah satu permasalahan lingkungan yang memiliki dampak serius terhadap kesehatan manusia dan keberlanjutan lingkungan [1]. Limbah B3 mengandung zat beracun, korosif, mudah terbakar, atau reaktif yang berpotensi mencemari tanah, air, dan udara apabila tidak dikelola dengan baik. Kesalahan dalam identifikasi dan pemilahan limbah B3 dapat menimbulkan risiko lingkungan jangka panjang serta membahayakan keselamatan manusia.

Seiring dengan meningkatnya aktivitas industri dan konsumsi masyarakat, volume dan variasi limbah B3 juga terus bertambah.[1] Limbah B3 tidak hanya dihasilkan oleh sektor industri, tetapi juga berasal dari aktivitas rumah tangga dan komersial, seperti aki dan battery bekas, bola lampu, botol bekas minyak dan thinner, kaleng semprot aerosol, limbah elektronik, serta limbah logam. Jenis-jenis limbah tersebut sering kali tercampur dengan limbah non-B3 karena keterbatasan pengetahuan masyarakat serta proses identifikasi yang masih dilakukan secara manual. Kondisi ini menunjukkan bahwa tahap klasifikasi limbah B3 masih menjadi permasalahan yang perlu ditangani secara lebih sistematis.[2]

Klasifikasi limbah secara manual memiliki sejumlah keterbatasan, seperti ketergantungan pada pengalaman manusia, potensi kesalahan akibat subjektivitas, serta rendahnya efisiensi ketika harus menangani limbah dalam jumlah besar. Selain itu, beberapa jenis limbah memiliki kemiripan karakteristik visual, sehingga sulit dibedakan hanya berdasarkan pengamatan langsung. Oleh karena itu, diperlukan pendekatan berbasis teknologi yang mampu membantu proses klasifikasi limbah B3 secara objektif dan konsisten.[3] Perkembangan kecerdasan buatan, khususnya deep learning, memberikan solusi potensial dalam pengolahan citra digital. Convolutional Neural Network (CNN) merupakan metode deep learning yang dirancang untuk mengenali pola visual dan telah banyak digunakan dalam berbagai penelitian klasifikasi citra. Penelitian yang dilakukan oleh Al-Mashhadani (2023) menunjukkan bahwa CNN mampu mengklasifikasikan material limbah secara efektif menggunakan data citra. Dalam penelitiannya, beberapa arsitektur CNN seperti ResNet50, GoogLeNet, InceptionV3, dan Xception dibandingkan, dan hasilnya menunjukkan bahwa model deep learning mampu mencapai tingkat akurasi yang tinggi dalam klasifikasi limbah. Temuan ini membuktikan bahwa pendekatan berbasis CNN layak digunakan untuk permasalahan klasifikasi limbah [2].

Selain itu, penelitian oleh Malik (2022) menunjukkan pentingnya klasifikasi limbah berbasis citra untuk mendukung pengelolaan limbah yang berkelanjutan. Penelitian tersebut menyoroti bahwa limbah seperti logam, baterai, limbah elektronik, dan material berbahaya lainnya memerlukan klasifikasi yang tepat karena memiliki dampak langsung terhadap lingkungan. Studi ini menunjukkan bahwa penggunaan model deep learning mampu meningkatkan efektivitas proses klasifikasi limbah dibandingkan metode konvensional.

Dari sisi arsitektur model, Ahsan (2022) membuktikan bahwa penggunaan VGG16 dengan pendekatan transfer learning mampu memberikan performa yang sangat baik pada klasifikasi citra, meskipun dataset yang digunakan relatif terbatas. Penelitian tersebut menunjukkan bahwa VGG16 efektif sebagai feature extractor karena mampu menangkap karakteristik visual [3]. Hasil serupa juga ditunjukkan oleh Pardede (2021) yang menerapkan transfer learning VGG16 pada klasifikasi citra dan memperoleh peningkatan akurasi yang signifikan dibandingkan metode machine learning tradisional. Penelitian tersebut menunjukkan bahwa VGG16 memiliki keunggulan dalam mengekstraksi fitur visual kompleks dan mengurangi permasalahan overfitting [4]

Berdasarkan hasil-hasil penelitian terdahulu tersebut, dapat disimpulkan bahwa klasifikasi berbasis citra menggunakan Convolutional Neural Network, khususnya arsitektur VGG16, merupakan pendekatan yang relevan dan efektif. Namun, penelitian yang secara spesifik membahas klasifikasi limbah B3 dengan kelas-kelas seperti aki, battery, bola lampu, botol minyak dan thinner, kaleng semprot aerosol, limbah elektronik, dan logam masih relatif terbatas. Oleh karena itu, penelitian ini berfokus pada penerapan model Convolutional Neural Network VGG16 untuk melakukan klasifikasi limbah B3 berbasis citra, dengan tujuan mengevaluasi kinerja model dalam mengenali berbagai jenis limbah B3 berdasarkan karakteristik visualnya.[4]

II. METODE

1. Lokasi dan Waktu Penelitian

Adapun lokasi dan waktu penelitian ini di laksanakan pada tanggal 18 – 20 Desember 2025 bertempat di Krembung, RT.19 RW.08 Kec. Krembung, Kab. Sidoarjo, Jawa Timur.

2. Alat dan Bahan Penelitian


- a) Hardware : Laptop dengan spek minimal prosesor AMD A8 atau Intel i5 dengan GPU AMD R5 atau Nvidia Geforce GT 730
- b) Software : Bahasa pemrograman Phyton, Google collab

3. Teknik Pengumpulan Data

Teknik pengumpulan data dilakukan secara primer melalui roboflow, dengan mengelompokkan data citra sesuai dengan kelasnya masing-masing.

4. Tahapan Analisis dan Pengembangan Sistem

Penelitian disusun berdasarkan tahapan pengembangan model klasifikasi citra menggunakan CNN VGG16. Secara umum, alur penelitian meliputi tahap pengumpulan data citra, preprocessing data, pembangunan model, pelatihan model, evaluasi model, dan pengujian prediksi citra. Alur penelitian ini digambarkan dalam flowchart proses klasifikasi limbah B3 berbasis citra menggunakan VGG16.



Gambar 3. 1 Flowchart

Gambaran output pada setiap langkah dalam penelitian ini adalah sebagai berikut:

- Data Augmentation



Gambar ini menampilkan proses data augmentation, yaitu teknik untuk memperbanyak variasi data

gambar dengan cara melakukan transformasi seperti rotasi, zoom, flip horizontal/vertical, dan pergeseran posisi.

Tujuan dari data augmentation adalah agar model tidak hanya menghafal gambar asli, tetapi mampu mengenali pola dari berbagai variasi sudut dan posisi gambar, sehingga performa model menjadi lebih robust dan mengurangi risiko overfitting.

- Base Model Summary

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 224, 224, 3)	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1,792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36,928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73,856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147,584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295,168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590,080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590,080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1,180,160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2,359,808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2,359,808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2,359,808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0

Output ini menunjukkan summary dari base model yang digunakan. Base model Model ini sudah dilatih sebelumnya (model yang telah terlatih) berperan sebagai feature extractor, sehingga mampu mengekstrak fitur penting dari citra tanpa perlu dilatih lagi.

- Output model.summary()

Layer (type)	Output Shape	Param #
vgg16 (Functional)	(None, 7, 7, 512)	14,714,688
dropout (Dropout)	(None, 7, 7, 512)	0
flatten (Flatten)	(None, 25088)	0
batch_normalization (BatchNormalization)	(None, 25088)	100,352
dense (Dense)	(None, 1024)	25,691,136
batch_normalization_1 (BatchNormalization)	(None, 1024)	4,096
activation (Activation)	(None, 1024)	0
dropout_1 (Dropout)	(None, 1024)	0
dense_1 (Dense)	(None, 1024)	1,049,600
batch_normalization_2 (BatchNormalization)	(None, 1024)	4,096
activation_1 (Activation)	(None, 1024)	0
dropout_2 (Dropout)	(None, 1024)	0
dense_2 (Dense)	(None, 7)	7,175

Output model.summary() ini merupakan hasil dari fungsi model.summary() yang menampilkan arsitektur keseluruhan model. Informasi yang ditampilkan meliputi jumlah layer, tipe layer, ukuran output setiap layer, serta total parameter yang digunakan. Dari output ini dapat diketahui jumlah parameter yang dilatih (trainable) dan yang tidak dilatih (non-trainable).

- Proses Model Fitting (Epoch)

```

/usr/local/lib/python3.12/dist-packages/keras/src/trainers/data_adapters/py_dataset_adapter.py:121: UserWarning: Your 'PyDataset' class should call 'super._warn_if_super_not_called()'
Epoch 1/30
23/41 — 6:28 22s/step - accuracy: 0.5182 - auc: 0.8197 - loss: 1.5544/usr/local/lib/python3.12/dist-packages/PIL/Image.py:1847: UserWarning:
warnings.warn(
41/41 — 0s 21s/step - accuracy: 0.5643 - auc: 0.8546 - loss: 1.3935
Epoch 1: val_auc improved from -inf to 0.91661, saving model to /content/drive/MyDrive/Klasifikasi Limbah/model/model-VGG16.h5
WARNING:absl:You are saving your model as an HDF5 file via 'model.save()' or 'keras.saving.save_model(model)'. This file format is considered legacy. We
41/41 — 985s 24s/step - accuracy: 0.5661 - auc: 0.8559 - loss: 1.3873 - val_accuracy: 0.6875 - val_auc: 0.9166 - val_loss: 1.0802
Epoch 2/30
41/41 — 0s 21s/step - accuracy: 0.7718 - auc: 0.9603 - loss: 0.6819
Epoch 2: val_auc improved from 0.91661 to 0.96182, saving model to /content/drive/MyDrive/Klasifikasi Limbah/model/model-VGG16.h5
WARNING:absl:You are saving your model as an HDF5 file via 'model.save()' or 'keras.saving.save_model(model)'. This file format is considered legacy. We
41/41 — 954s 23s/step - accuracy: 0.7728 - auc: 0.9603 - loss: 0.6812 - val_accuracy: 0.7750 - val_auc: 0.9618 - val_loss: 0.6667
Epoch 3/30
41/41 — 0s 21s/step - accuracy: 0.8196 - auc: 0.9762 - loss: 0.5228
Epoch 3: val_auc did not improve from 0.96182
41/41 — 953s 23s/step - accuracy: 0.8196 - auc: 0.9762 - loss: 0.5222 - val_accuracy: 0.8000 - val_auc: 0.9341 - val_loss: 0.8387
Epoch 4/30
41/41 — 0s 21s/step - accuracy: 0.8302 - auc: 0.9788 - loss: 0.4888
Epoch 4: val_auc did not improve from 0.96182
41/41 — 895s 22s/step - accuracy: 0.8305 - auc: 0.9789 - loss: 0.4884 - val_accuracy: 0.7750 - val_auc: 0.9427 - val_loss: 0.8915
Epoch 5/30
41/41 — 0s 21s/step - accuracy: 0.8700 - auc: 0.9863 - loss: 0.3787
Epoch 5: val_auc did not improve from 0.96182
41/41 — 896s 22s/step - accuracy: 0.8699 - auc: 0.9863 - loss: 0.3790 - val_accuracy: 0.7375 - val_auc: 0.9526 - val_loss: 0.7730
Epoch 6/30
41/41 — 0s 21s/step - accuracy: 0.8961 - auc: 0.9888 - loss: 0.3270
Epoch 6: val_auc did not improve from 0.96182
41/41 — 896s 22s/step - accuracy: 0.8957 - auc: 0.9888 - loss: 0.3277 - val_accuracy: 0.7750 - val_auc: 0.9340 - val_loss: 0.9293
Epoch 7/30
41/41 — 0s 21s/step - accuracy: 0.8914 - auc: 0.9918 - loss: 0.2912
Epoch 7: val_auc did not improve from 0.96182
41/41 — 903s 22s/step - accuracy: 0.8912 - auc: 0.9918 - loss: 0.2920 - val_accuracy: 0.8000 - val_auc: 0.9350 - val_loss: 1.0772
Epoch 7: early stopping

```

Langkah ini menampilkan proses training model yang ditunjukkan melalui nilai epoch. Setiap epoch merepresentasikan satu kali proses pelatihan model terhadap seluruh data training. Pada tahap ini dapat dilihat nilai loss dan accuracy yang menunjukkan bagaimana model belajar dan menyesuaikan bobotnya dari waktu ke waktu.

5. Dataset Penelitian

Total dataset yang digunakan dalam penelitian ini adalah 2910 citra dengan persentase data train sebanyak 56%, data validation sebanyak 14%, dan data test sebanyak 30%. Dataset yang digunakan dalam penelitian ini diklasifikasikan ke dalam tujuh kelas dengan rincian sebagai berikut:

Copyright © Universitas Muhammadiyah Sidoarjo. This preprint is protected by copyright held by Universitas Muhammadiyah Sidoarjo and is distributed under the Creative Commons Attribution License (CC BY). Users may share, distribute, or reproduce the work as long as the original author(s) and copyright holder are credited, and the preprint server is cited per academic standards.

Authors retain the right to publish their work in academic journals where copyright remains with them. Any use, distribution, or reproduction that does not comply with these terms is not permitted..

1. Aki (test 90 data, train 168 data, validation 42 data), total 300 data
2. Battery (test 150 data, train 280 data, validation 70 data), total 500 data
3. Bola lampu (test 160 data, train 280 data, validation 70 data), total 510 data
4. Botol minyak (test 90 data, train 168 data, validation 42 data), total 300 data
5. Kaleng semprot (test 90 data, train 168 data, validation 42 data), total 300 data
6. Limbah (test 150 data, train 280 data, validation 70 data), total 500 data
7. Logam (test 150 data, train 280 data, validation 70 data), total 500 data

Dataset disusun dalam struktur folder yang terpisah untuk data training, validation, dan testing. Setiap citra mewakili satu objek limbah B3 dan digunakan sebagai input dalam proses pelatihan dan evaluasi model.

6. Preprocessing Data

Tahap preprocessing bertujuan untuk menyiapkan data citra agar sesuai dengan kebutuhan model VGG16. Proses preprocessing dilakukan menggunakan ImageDataGenerator dengan tahapan sebagai berikut:

1. Resize citra menjadi ukuran 224×224 piksel.
2. Normalisasi citra dengan skala $1/255$.
3. Augmentasi data pada data training, meliputi rotasi, zoom, dan flipping horizontal serta vertikal untuk meningkatkan variasi data.

7. Pembangunan Model Klasifikasi

Model klasifikasi dibangun menggunakan arsitektur VGG16 pretrained ImageNet sebagai base model. Pada tahap ini, seluruh layer pada base model dibekukan (freeze) agar bobot pretrained tidak berubah selama proses pelatihan.

Selanjutnya, ditambahkan beberapa layer pada bagian akhir model untuk menyesuaikan dengan jumlah kelas limbah B3, yaitu:

- Dropout
- Flatten
- Batch Normalization
- Activation (ReLU)
- Dense dengan fungsi aktivasi Softmax

8. Proses Pelatihan Model

Model yang telah dibangun kemudian dikompilasi menggunakan:

- Optimizer: Adam
- Learning rate: 0.001
- Loss function: Categorical Crossentropy
- Metrics: Accuracy dan AUC

Proses pelatihan dilakukan menggunakan data training dan data validation dengan jumlah epoch maksimal sebanyak 30. Untuk mengoptimalkan proses pelatihan, digunakan callback *EarlyStopping* untuk menghentikan pelatihan apabila kinerja model tidak mengalami peningkatan, serta *ModelCheckpoint* untuk menyimpan model terbaik berdasarkan nilai validasi AUC.

9. Evaluasi Model

Evaluasi model dilakukan menggunakan data testing yang tidak terlibat dalam proses pelatihan.

Tahapan evaluasi meliputi:

1. Melakukan prediksi terhadap data testing.
2. Menghitung nilai confusion matrix.
3. Menghasilkan classification report yang berisi nilai precision, recall, dan f1-score untuk setiap kelas.
4. Melakukan visualisasi confusion matrix untuk melihat performa klasifikasi tiap kelas.

10. Pengujian Prediksi Citra Tunggal


Selain evaluasi menggunakan data testing, model juga diuji menggunakan citra tunggal. Pada tahap ini, citra diuji melalui proses resize, normalisasi, dan prediksi menggunakan model terbaik. Hasil prediksi berupa label kelas limbah B3 yang ditampilkan bersama citra input. Pengujian ini dilakukan untuk memastikan bahwa model mampu melakukan klasifikasi pada citra baru di luar data pelatihan.

III. HASIL DAN PEMBAHASAN

1. Hasil Pelatihan Model VGG16

Proses pelatihan dilakukan menggunakan model VGG16 dengan pendekatan *transfer learning*. Model menggunakan bobot awal dari ImageNet, sedangkan lapisan dasar VGG16 dibekukan (*freeze*) dan ditambahkan lapisan klasifikasi untuk mengenali tujuh kelas limbah B3. Proses pelatihan menggunakan optimizer Adam dengan *learning rate* sebesar 0,001 dan fungsi *loss categorical crossentropy* sebagaimana telah dijelaskan pada tahap metode penelitian.


Berdasarkan hasil pelatihan, model mengalami peningkatan *training accuracy* dari sekitar 0,66 pada epoch pertama menjadi sekitar 0,91 pada epoch ke-9, kemudian sedikit menurun menjadi sekitar 0,90 pada epoch ke-10. Sementara itu, nilai *training loss* menunjukkan kecenderungan menurun dari sekitar 1,08 pada epoch pertama menjadi sekitar 0,29 pada epoch ke-9, kemudian sedikit meningkat menjadi sekitar 0,31 pada epoch ke-10.



Gambar 1 Grafik Training Accuracy dan Training Loss

Hasil tersebut menunjukkan bahwa model VGG16 mampu mempelajari karakteristik visual dari citra limbah B3 selama proses pelatihan. Peningkatan *accuracy* yang disertai dengan penurunan *loss* menunjukkan bahwa model semakin mampu melakukan klasifikasi terhadap data yang digunakan dalam proses pembelajaran.

Meskipun demikian, peningkatan performa pada data latih tidak sepenuhnya diikuti oleh peningkatan performa pada data validasi. Berdasarkan grafik validasi, *validation accuracy* berfluktuasi pada kisaran 0,71–0,83, sedangkan *validation loss* berada pada kisaran sekitar 0,61–0,97. *Validation accuracy* tertinggi mencapai sekitar 0,83, sedangkan nilai *validation loss* terendah berada pada sekitar 0,61.



Gambar 2 Grafik *Validation Accuracy* dan *Validation Loss*

Perbedaan pola antara data latih dan validasi menunjukkan bahwa model memiliki kemampuan belajar yang baik terhadap data latih, tetapi performanya terhadap data yang tidak digunakan secara langsung dalam pembelajaran masih berfluktuasi. Kondisi tersebut dapat mengindikasikan adanya kecenderungan *overfitting*, karena *training accuracy* meningkat hingga sekitar 90%, sedangkan *validation accuracy* tidak menunjukkan peningkatan yang konsisten. Penggunaan augmentasi pada data latih dan mekanisme *EarlyStopping* pada penelitian ini menjadi bagian dari upaya untuk mengurangi permasalahan tersebut.

2. Hasil Evaluasi Model

Setelah proses pelatihan, model terbaik digunakan untuk melakukan pengujian terhadap data uji. Data uji yang digunakan berjumlah 880 citra yang terdiri atas tujuh kelas limbah B3. Evaluasi dilakukan menggunakan *confusion matrix* dan *classification report* yang mencakup nilai *precision*, *recall*, *F1-score*, dan *accuracy*, sesuai dengan metode evaluasi yang telah ditentukan. Hasil evaluasi model ditunjukkan pada Tabel 1.

Tabel 1 Hasil Classification Report Model VGG16

Kelas	Precision	Recall	F1-score	Support
Aki	0,83	0,87	0,85	90
Baterai	0,81	0,71	0,75	150
Bola lampu	0,81	0,72	0,77	160
Botol minyak dan thinner	0,89	0,98	0,93	90
Kaleng semprot aerosol	0,55	0,60	0,57	90
Limbah elektronik	0,86	0,87	0,86	150
Logam	0,66	0,71	0,69	150
Accuracy			0,77	880
Macro average	0,77	0,78	0,77	880
Weighted average	0,78	0,77	0,77	880

Berdasarkan Tabel 1, model VGG16 memperoleh accuracy sebesar 0,77 atau 77% pada 880 data uji. Nilai *macro average* menunjukkan *precision* sebesar 0,77, *recall* sebesar 0,78, dan *F1-score* sebesar 0,77. Sementara itu, *weighted average* menghasilkan *precision* sebesar 0,78, *recall* sebesar 0,77, dan *F1-score* sebesar 0,77.

Hasil tersebut menunjukkan bahwa model mampu melakukan klasifikasi terhadap sebagian besar citra dengan tingkat ketepatan sebesar 77%. Namun, performa model masih berbeda antar kelas. Perbedaan tersebut dapat dilihat dari nilai *precision*, *recall*, dan *F1-score* pada masing-masing kelas.

3. Analisis Performa Berdasarkan Kelas

Kelas botol minyak dan thinner memiliki performa klasifikasi paling tinggi dengan nilai *precision* sebesar 0,89, *recall* sebesar 0,98, dan *F1-score* sebesar 0,93. Nilai *recall* yang mencapai 0,98 menunjukkan bahwa hampir seluruh

citra botol minyak dan thinner pada data uji berhasil dikenali oleh model sebagai kelas yang sesuai. Tingginya performa tersebut menunjukkan bahwa karakteristik visual kelas ini relatif mudah dibedakan oleh model dibandingkan dengan kelas lainnya.

Kelas aki juga menunjukkan performa yang cukup baik dengan *precision* sebesar 0,83, *recall* sebesar 0,87, dan *F1-score* sebesar 0,85. Hasil tersebut menunjukkan bahwa sebagian besar citra aki dapat dikenali dengan baik oleh model.

Selanjutnya, kelas limbah elektronik memperoleh *precision* sebesar 0,86, *recall* sebesar 0,87, dan *F1-score* sebesar 0,86. Nilai tersebut menunjukkan kemampuan model yang cukup baik dalam mengenali limbah elektronik. Hal ini menunjukkan bahwa karakteristik visual pada citra limbah elektronik masih dapat dipelajari dengan cukup baik oleh VGG16.

Pada kelas baterai, model memperoleh *precision* sebesar 0,81, *recall* sebesar 0,71, dan *F1-score* sebesar 0,75. Nilai *precision* yang lebih tinggi dibandingkan *recall* menunjukkan bahwa ketika model memprediksi suatu citra sebagai baterai, prediksi tersebut relatif cukup tepat, tetapi masih terdapat sejumlah citra baterai yang gagal dikenali sebagai kelas baterai.


Kelas bola lampu memperoleh *precision* sebesar 0,81, *recall* sebesar 0,72, dan *F1-score* sebesar 0,77. Hasil tersebut menunjukkan pola yang hampir sama dengan kelas baterai, yaitu model memiliki ketepatan prediksi yang cukup baik, tetapi masih mengalami kesulitan dalam mengenali seluruh citra bola lampu yang sebenarnya.

Sementara itu, kelas logam memperoleh *precision* sebesar 0,66, *recall* sebesar 0,71, dan *F1-score* sebesar 0,69. Nilai tersebut menunjukkan bahwa klasifikasi logam masih mengalami kesalahan yang cukup besar. Karakteristik visual logam yang dapat memiliki bentuk dan tampilan yang beragam memungkinkan terjadinya kemiripan dengan beberapa kelas limbah lainnya.

Performa paling rendah diperoleh pada kelas kaleng semprot aerosol, dengan *precision* sebesar 0,55, *recall* sebesar 0,60, dan *F1-score* sebesar 0,57. Hasil tersebut menunjukkan bahwa model masih mengalami kesulitan dalam membedakan citra kaleng semprot aerosol. Nilai *precision* yang rendah juga menunjukkan bahwa cukup banyak citra dari kelas lain yang diprediksi sebagai kaleng semprot aerosol.

4. Analisis Confusion Matrix

Hasil *confusion matrix* dari 880 data uji ditunjukkan pada Gambar 4.



Gambar 3 Confusion Matrix Model VGG16

Berdasarkan *confusion matrix*, jumlah prediksi yang benar pada masing-masing kelas ditunjukkan oleh nilai diagonal. Model berhasil mengklasifikasikan 78 dari 90 citra aki, 106 dari 150 citra baterai, 116 dari 160 citra bola lampu, 88 dari 90 citra botol minyak dan thinner, 54 dari 90 citra kaleng semprot aerosol, 131 dari 150 citra limbah elektronik, dan 107 dari 150 citra logam. Sehingga jumlah prediksi yang benar secara keseluruhan adalah 680 dari 880 citra, sehingga menghasilkan tingkat akurasi sebesar 77%.

Kesalahan klasifikasi paling terlihat pada beberapa pasangan kelas yang memiliki karakteristik visual yang relatif berdekatan. Pada kelas baterai, misalnya, terdapat citra yang diprediksi sebagai kaleng semprot aerosol maupun logam. Sementara itu, beberapa citra bola lampu juga diprediksi sebagai logam. Kondisi tersebut menunjukkan bahwa model masih menghadapi kesulitan ketika karakteristik visual suatu objek memiliki kemiripan dengan kelas lainnya.

Pada kelas kaleng semprot aerosol, hanya 54 dari 90 citra yang berhasil diklasifikasikan dengan benar. Sebagian citra kelas tersebut diprediksi sebagai logam, baterai, maupun limbah elektronik. Pola kesalahan tersebut sejalan dengan nilai *F1-score* kelas kaleng semprot aerosol yang menjadi nilai terendah, yaitu 0,57.

Sebaliknya, kelas botol minyak dan thinner menunjukkan hasil yang sangat baik. Dari 90 citra, sebanyak 88 citra berhasil diklasifikasikan dengan benar. Hanya dua citra yang mengalami kesalahan klasifikasi. Hasil ini sesuai dengan nilai *recall* sebesar 0,98 dan *F1-score* sebesar 0,93 yang diperoleh kelas tersebut.

5. Pembahasan

Penerapan VGG16 dengan pendekatan *transfer learning* menghasilkan *accuracy* sebesar 77% pada data uji dengan nilai *F1-score* rata-rata sebesar 0,77. Hasil tersebut menunjukkan bahwa model mampu mempelajari karakteristik visual dari tujuh kelas limbah B3 yang digunakan dalam penelitian. Namun, masih ditemukan kesalahan klasifikasi pada beberapa kelas, terutama pada kaleng semprot aerosol, logam, baterai, dan bola lampu.

Hasil pelatihan menunjukkan peningkatan *training accuracy* hingga sekitar 90%, sedangkan *validation accuracy* berada pada rentang 71–83%. Perbedaan performa antara data latih dan data validasi menunjukkan bahwa model lebih baik dalam mengenali data yang digunakan selama proses pembelajaran dibandingkan data validasi. Kondisi ini mengindikasikan adanya kecenderungan *overfitting* sehingga kemampuan generalisasi model masih perlu ditingkatkan.

Perbedaan nilai performa pada setiap kelas juga menunjukkan bahwa karakteristik visual objek berpengaruh terhadap hasil klasifikasi. Kelas botol minyak dan thinner memperoleh performa tertinggi dengan *F1-score* sebesar 0,93, sedangkan kaleng semprot aerosol memperoleh *F1-score* terendah sebesar 0,57. Perbedaan tersebut menunjukkan bahwa beberapa jenis limbah memiliki karakteristik visual yang lebih mudah dikenali oleh model dibandingkan jenis limbah lainnya.

Kesalahan klasifikasi pada kelas kaleng semprot aerosol, logam, baterai, dan bola lampu menunjukkan bahwa model masih mengalami kesulitan dalam membedakan objek dengan karakteristik visual yang memiliki kemiripan. Kondisi tersebut terlihat pada *confusion matrix*, ketika sejumlah citra dari kelas tersebut diprediksi sebagai kelas lain. Hasil ini menunjukkan perlunya peningkatan kualitas dan keragaman data agar model memperoleh variasi karakteristik visual yang lebih banyak selama proses pembelajaran.

Penggunaan VGG16 pada penelitian ini memanfaatkan bobot awal dari ImageNet melalui pendekatan *transfer learning*. Lapisan dasar VGG16 dibekukan, kemudian ditambahkan lapisan klasifikasi yang disesuaikan dengan tujuh kelas limbah B3. Pendekatan tersebut memungkinkan model menggunakan fitur visual yang telah diperoleh dari proses pembelajaran sebelumnya untuk membantu proses klasifikasi citra limbah B3.

Model VGG16 menghasilkan *accuracy* sebesar 77% pada data uji sehingga dapat digunakan untuk membantu proses klasifikasi limbah B3 berbasis citra. Peningkatan performa masih diperlukan, khususnya pada kelas dengan nilai *F1-score* rendah. Perbaikan dapat dilakukan melalui penambahan variasi citra, pengoptimalan augmentasi, serta penyesuaian konfigurasi model pada penelitian berikutnya.

IV. SIMPULAN

Penelitian ini menerapkan metode *Convolutional Neural Network* (CNN) menggunakan arsitektur VGG16 dengan pendekatan *transfer learning* untuk melakukan klasifikasi citra limbah B3 ke dalam tujuh kelas, yaitu aki, baterai, bola lampu, botol minyak dan thinner, kaleng semprot aerosol, limbah elektronik, dan logam. Model dilatih menggunakan bobot awal ImageNet dengan lapisan dasar VGG16 yang dibekukan serta penambahan lapisan klasifikasi.

Hasil pengujian terhadap 880 citra menunjukkan bahwa model memperoleh *accuracy* sebesar 77% dengan nilai *F1-score* sebesar 0,77. Kelas botol minyak dan thinner memperoleh performa terbaik dengan *F1-score* sebesar 0,93, sedangkan kelas kaleng semprot aerosol memperoleh performa terendah dengan *F1-score* sebesar 0,57. Hasil tersebut menunjukkan bahwa VGG16 mampu melakukan klasifikasi limbah B3 berbasis citra, tetapi kemampuan model dalam mengenali beberapa kelas masih perlu ditingkatkan. Perbaikan dapat dilakukan melalui penambahan jumlah dan variasi dataset, pengoptimalan augmentasi citra, serta penyesuaian arsitektur dan parameter pelatihan pada penelitian selanjutnya.

REFERENSI

- [1] S. Aji and D. H. Wardhani, "Pengolahan Limbah Bahan Berbahaya dan Beracun (B3) dengan Teknologi Insinerasi pada Fasilitas Pengelolaan Limbah Terpadu (FPLT) Kawasan Medan," vol. 2, no. 1, pp. 17–25, 2024.
- [2] I. Cetak, I. Online, and J. Sampah, "DECODE : Jurnal Pendidikan Teknologi Informasi," vol. 3, no. 2, pp. 407–419, 2023.
- [3] I. B. Al-mashhadani, "Waste material classification using performance evaluation of deep learning models," 2023.
- [4] J. Pardede, "Implementation of Transfer Learning Using VGG16 on Fruit Ripeness Detection," no. April, pp. 52–61, 2021, doi: 10.5815/ijisa.2021.02.04.
- [5] M. Hossen et al., "A Reliable and Robust Deep Learning Model for Effective Recyclable Waste Classification," no. January, pp. 13809–13821, 2024.
- [6] J. Choi, B. Lim, and Y. Yoo, "applied sciences Advancing Plastic Waste Classification and Recycling Efficiency : Integrating Image Sensors and Deep Learning Algorithms," 2023.
- [7] J. Qi, M. Nguyen, and W. Q. Yan, "Waste Classification from Digital Images Using ConvNeXt."
- [8] M. M. Hossen et al., "A reliable and robust deep learning model for effective recyclable waste classification," IEEE Access, vol. 12, pp. 13809–13821, 2024.
- [9] J. Qi, M. Nguyen, and W. Q. Yan, "Waste classification from digital images using ConvNeXt," in Pacific-Rim Symposium on Image and Video Technology, 2022, pp. 1–13.
- [10] T. Yoo, S. Lee, and T. Kim, "Dual image-based cnn ensemble model for waste classification in reverse vending machine," Appl. Sci., vol. 11, no. 22, p. 11051, 2021.
- [11] J. Choi, B. Lim, and Y. Yoo, "Advancing plastic waste classification and recycling efficiency: Integrating image sensors and deep learning algorithms," Appl. Sci., vol. 13, no. 18, p. 10224, 2023.
- [12] S. Majchrowska et al., "Deep learning-based waste detection in natural and urban environments," Waste Manag., vol. 138, pp. 274–284, 2022.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.