

Penerapan Metode Convolutional Neural Network Untuk Klasifikasi Jenis Sampah Bawah Air

Krisna Dwi Septian, Noor Khalisa, Imran Djafar*, Arwansyah

Jurusan Teknik Informatika, Universitas Dipa Makassar, Makassar Sulawesi Selatan

e-mail: ¹krisnadwiseptian@gmail.com, ²noorkhalisa02@gmail.com,

³imrandjafar@undipa.ac.id, ⁴arwansyah@undipa.ac.id

Abstrak

Perkembangan teknologi kecerdasan buatan, khususnya deep learning, telah membuka peluang baru dalam identifikasi sampah bawah air. Penelitian ini mengembangkan arsitektur Convolutional Neural Network (CNN) kustom untuk mengklasifikasikan jenis sampah bawah air ke dalam dua kategori: plastik dan non-plastik. Dataset yang digunakan terdiri dari 600 gambar hasil pengambilan langsung di lingkungan perairan dengan kamera GoPro Hero 11, kemudian dibagi menjadi data latih (70%), validasi (15%), dan uji (15%). Arsitektur CNN yang dikembangkan terdiri dari tiga lapisan konvolusi (Conv2D) dengan masing-masing 32, 64, dan 128 filter ukuran 3×3, yang diikuti oleh max pooling 2×2, lapisan flatten, dan dua dense layer, masing-masing dengan 128 neuron (ReLU) dan 2 neuron (Softmax) untuk klasifikasi. Untuk mencegah overfitting, digunakan teknik dropout sebelum lapisan output. Model dilatih selama 50 epoch menggunakan optimizer Adam dan fungsi loss categorical cross-entropy, serta diimplementasikan menggunakan platform TensorFlow dan Keras pada Google Colab. Evaluasi kinerja dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, dan confusion matrix. Hasil pelatihan menunjukkan bahwa model mampu mencapai akurasi 89%, dengan presisi 95% untuk kategori plastik dan 84% untuk non-plastik. Meskipun menunjukkan performa yang baik, model masih menghadapi tantangan dalam menghadapi kondisi lingkungan yang dinamis, seperti variasi pencahayaan dan kemiripan tekstur antar objek. Penelitian mendatang disarankan untuk memperluas ukuran dataset dan mengeksplorasi arsitektur yang lebih kompleks atau metode transfer learning guna meningkatkan akurasi klasifikasi.

Kata kunci—Convolutional Neural Network (CNN), Klasifikasi sampah, Sampah bawah air, Deep learning.

Abstract

The advancement of artificial intelligence technology, particularly deep learning, has opened new opportunities in underwater waste identification. This study develops a custom Convolutional Neural Network (CNN) architecture to classify underwater waste into two categories: plastic and non-plastic. The dataset consists of 600 images collected directly from aquatic environments using a GoPro Hero 11 camera and is divided into training (70%), validation (15%), and testing (15%) sets. The developed CNN architecture comprises three convolutional layers (Conv2D) with 32, 64, and 128 filters of size 3×3, each followed by 2×2 max pooling layers, a flatten layer, and two dense layers with 128 neurons (ReLU) and 2 output neurons (Softmax) for classification. To prevent overfitting, a dropout technique is applied before the output layer. The model is trained for 50 epochs using the Adam optimizer and categorical cross-entropy loss function, implemented on the TensorFlow and Keras platforms via Google Colab. Model performance is evaluated using accuracy, precision, recall, F1-score, and a confusion matrix. The results show that the model achieves an accuracy of 89%, with a precision of 95% for the plastic category and 84% for the non-plastic category. Although the

model demonstrates strong performance, it still faces challenges in handling dynamic underwater conditions, such as variations in lighting and similarities in object textures. Future research is recommended to increase dataset size and explore more complex architectures or transfer learning techniques to enhance classification accuracy.

Keywords—Convolutional Neural Network (CNN), Garbage classification, Underwater garbage, Deep learning.

1. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan, khususnya dalam bidang deep learning, telah memberikan kontribusi signifikan terhadap kemampuan sistem komputer dalam mengenali pola visual secara otomatis dan efisien. Salah satu pendekatan paling populer dalam pengolahan citra digital adalah Convolutional Neural Network (CNN), yang dikenal memiliki performa tinggi dalam tugas-tugas klasifikasi visual seperti pengenalan objek, segmentasi gambar, hingga deteksi sampah [1], [2].

Dalam konteks lingkungan, pencemaran oleh sampah plastik di laut telah menjadi isu global yang mendesak. Sampah plastik tidak hanya mencemari ekosistem laut, tetapi juga mengancam kehidupan biota laut serta rantai makanan manusia [3]. Proses klasifikasi sampah secara manual di lingkungan bawah air dinilai kurang efisien dan sangat rentan terhadap kesalahan, terutama karena faktor-faktor lingkungan seperti air keruh, cahaya redup, serta bentuk dan warna sampah yang beragam.

Beberapa penelitian sebelumnya telah membuktikan efektivitas CNN dalam mengklasifikasikan citra visual sampah. Misalnya, penelitian [4] berhasil mengklasifikasikan sampah organik dan non-organik dengan akurasi hingga 99% menggunakan CNN. Sementara itu, [5] menggunakan arsitektur ResNet50 untuk klasifikasi enam jenis sampah plastik dan mencapai akurasi validasi 99,44% setelah 150 epoch. Namun, sebagian besar penelitian tersebut masih menggunakan dataset yang diperoleh dari lingkungan terkendali, bukan kondisi nyata di bawah air.

Oleh karena itu, penelitian ini berfokus pada pengembangan model CNN kustom untuk klasifikasi sampah bawah air, menggunakan dataset yang diambil secara langsung dari lingkungan perairan menggunakan kamera GoPro Hero 11, dengan berbagai kondisi nyata seperti pencahayaan alami, pergerakan air, dan variasi tekstur objek. Model dikembangkan dari awal dengan arsitektur CNN tiga lapis konvolusi yang dioptimalkan menggunakan TensorFlow dan Keras, serta diuji untuk mengklasifikasikan sampah menjadi dua kategori: plastik dan non-plastik.

Dengan pendekatan ini, penelitian diharapkan mampu memberikan kontribusi dalam pengembangan sistem otomatis untuk mendeteksi dan mengklasifikasikan sampah bawah air secara akurat dan efisien. Sistem semacam ini berpotensi diterapkan dalam robot pemantau laut, sistem manajemen sampah otomatis, serta sebagai dasar untuk pengembangan sistem klasifikasi berbasis transfer learning yang lebih kompleks [6], [7].

2. METODE PENELITIAN

2.1 Jenis Penelitian

Jenis penelitian ini adalah eksperimental, yang bertujuan membangun dan mengevaluasi performa model Convolutional Neural Network (CNN) dalam mengklasifikasikan jenis sampah bawah air berdasarkan citra visual. Model CNN yang digunakan dibangun secara custom dari awal (from scratch) tanpa memanfaatkan pre-trained models, agar dapat menyesuaikan struktur dengan karakteristik dataset bawah air.

2.2 Dataset dan Pengumpulan Data

Data dikumpulkan langsung dari lingkungan pantai menggunakan kamera bawah air GoPro Hero 11. Dataset terdiri dari 600 citra beresolusi tinggi dengan komposisi seimbang antara sampah plastik (300 gambar) dan non-plastik (300 gambar). Gambar diambil pada kedalaman antara 30 cm hingga 80 cm, lalu dikonversi dari format video menjadi citra. Dataset dibagi menjadi tiga bagian: data latih (70%), validasi (15%), dan uji (15%).

2.3 Preprocessing dan Augmentasi

Citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan input standar CNN [8], [9], [10]. Proses normalisasi dilakukan dengan mengubah rentang nilai piksel dari $[0-255]$ menjadi $[0-1]$. Untuk meningkatkan generalisasi model dan menghindari overfitting, diterapkan augmentasi data seperti rotasi (15°), translasi horizontal/vertikal (20%), zoom (20%), dan flipping horizontal. Proses ini dilakukan menggunakan modul ImageDataGenerator dari pustaka Keras.

2.4 Bahan dan Alat Penelitian

2.4.1 Bahan Penelitian

Dataset Gambar dan Video yang diambil di pantai menggunakan kamera GoPro Hero 11. Data ini terdiri dari berbagai jenis sampah yang ditemukan di bawah air, seperti sampah plastik dan nonplastik (kaleng, sepatu, kain dan kaca) sebagai objek. Data yang diperoleh kemudian akan digunakan sebagai input untuk pelatihan model.

2.4.2 Alat Penelitian

Tabel 1 Alat Penelitian

No	Hardware	Spesifikasi
1.	Kamera GoPro Hero 11: Kamera ini digunakan untuk mengambil gambar dan video di bawah air saat pengambilan sampah di pantai. GoPro Hero 11 memiliki kemampuan tahan air, sehingga ideal untuk pengambilan gambar bawah air dengan resolusi tinggi yang dibutuhkan untuk pelatihan model CNN.	1. Jenis Sensor dan Resolusi CMOS / 27MP 2. Dimensi dan Berat 71,8 x 50,8 x 33,6 mm (127 gram) 3. Panjang Fokus 24,4 mm 4. Media Penyimpanan microSD/microSDHC (UHS-III) [Maksimal 256 GB / U3/V30 atau di atasnya] 5. Format Video 5312 x 2988 pada 60 fps (MP4 melalui H.265/HEVC) 2704 x 1520 pada 240 fps (MP4 melalui H.265/HEVC) 6. Mode Gerak Lambat 240 fps pada perekaman 2704 x 1520p
2.	Komputer/Laptop: Diperlukan untuk mendukung proses ekstraksi, pelabelan gambar, serta pemrosesan data menggunakan platform machine learning. Komputer juga digunakan untuk mengakses Google Colab.	1. LAPTOP-JM4CRVQE 2. Windows 11 Home Single Language 64-bit (10.0, Build 22631) 3. ASUSTeK COMPUTER INC 4. VivoBook_ASUSLaptop K3402ZA_K3402ZA 5. 12 th Gen Intel® Core™ i5-12500H (16 CPUs), ~2.5GHz 6. 12288MB RAM 7. DirectX 12

2.5 Arsitektur CNN yang Digunakan

Model CNN yang dikembangkan terdiri atas beberapa lapisan konvolusi dan pooling, serta fully connected layer [11], dengan detail sebagai berikut:

Tabel 2 Model CNN

Layer	Jenis	Ukuran Output	Filter	Aktivasi
1	Conv2D	(222, 222, 32)	32 filter (3×3)	ReLU
2	MaxPooling2D	(111, 111, 32)	(2×2)	-
3	Conv2D	(109, 109, 64)	64 filter (3×3)	ReLU
4	MaxPooling2D	(54, 54, 64)	(2×2)	-

Layer	Jenis	Ukuran Output	Filter	Aktivasi
5	Conv2D	(52, 52, 128)	128 filter (3×3)	ReLU
6	MaxPooling2D	(26, 26, 128)	(2×2)	-
7	Flatten	(86528)	-	-
8	Dense	(128)	-	ReLU
9	Dropout	(128)	0.5	-
10	Dense (Output)	(2)	-	Softmax

2.6 Proses Pelatihan Model

Model dilatih menggunakan dataset yang telah diproses, dan performa dievaluasi terhadap data uji. Pelatihan model dilakukan menggunakan:

- Optimizer: Adam
- Loss Function: Categorical Crossentropy
- Epoch: 50
- Batch Size: 32
- Validation Split: 15%
- Platform Pelatihan: Google Colab dengan TensorFlow dan Keras.


2.7 Evaluasi Kinerja Model

Evaluasi dilakukan untuk masing-masing kelas (plastik dan non-plastik) guna melihat distribusi kesalahan klasifikasi secara lebih rinci. Evaluasi dilakukan dengan menggunakan metrik [12]:

- Akurasi: Mengukur proporsi klasifikasi yang benar dari total prediksi
- Presisi: Mengukur akurasi model dalam memprediksi kelas positif
- Recall: Mengukur sensitivitas model terhadap kelas positif
- F1-score: Rata-rata harmonis antara presisi dan recall
- Confusion Matrix: Matriks perbandingan prediksi vs label aktual untuk tiap kelas.

3. HASIL DAN PEMBAHASAN

3.1 Perancangan Solusi



Gambar 1. Alur Perancangan Solusi

Gambar 1 memperlihatkan alur perancangan solusi dalam penelitian ini, mulai dari pengumpulan data hingga evaluasi model. Secara ringkas, tahapan yang dilakukan adalah sebagai berikut:

3.2.1 Pengumpulan Data

Dataset dikumpulkan di area pantai sebagai langkah awal. Pengambilan gambar dan video bawah air dilakukan menggunakan kamera GoPro Hero 11 pada kedalaman setinggi pinggang orang dewasa ($\pm 30\text{--}80\text{ cm}$), dengan berbagai objek sampah (plastik dan non-plastik) sebagai target tangkapan citra. Langkah ini menghasilkan kumpulan data mentah berupa rekaman video dan foto sampah bawah air.


3.2.2 Ekstraksi Frame Gambar

Video bawah air yang telah direkam kemudian dikonversi menjadi frame-frame gambar. Langkah ini diperlukan agar data sesuai dengan format input yang diperlukan model (yaitu berupa citra statis individual). Dari proses ini diperoleh sejumlah gambar yang siap diproses lebih lanjut.

3.2.3 Preprocessing Data

Data citra yang terkumpul selanjutnya diproses agar model dapat menerima dan mengolahnya secara optimal:

- Pelabelan Data:** Setiap gambar diberi label secara manual sesuai kategori yang benar (plastik atau non-plastik). Pelabelan ini memastikan bahwa model menerima data teranotasi dengan benar, sehingga dapat belajar membedakan kedua kelas sampah tersebut dengan akurat selama fase pelatihan.
- Resize Gambar:** Setiap citra diubah ukurannya menjadi 224×224 piksel agar semua input memiliki dimensi yang seragam. Langkah ini penting untuk efisiensi pemrosesan oleh model. (Gambar 2 menunjukkan contoh citra sebelum dan sesudah dilakukan resize menggunakan ImageDataGenerator dengan parameter `target_size=(224, 224)`).



Gambar 2. Sebelum dan Sesudah Resize


- Augmentasi Data:** Diterapkan teknik augmentasi untuk memperkaya variasi data latih tanpa perlu menambah data baru secara manual. Augmentasi dilakukan menggunakan ImageDataGenerator dengan parameter rotasi 15° , pergeseran lebar dan tinggi hingga 20%, zoom hingga 20%, flipping horizontal, serta `fill_mode = 'nearest'`. (Gambar 3 menampilkan potongan kode yang digunakan untuk proses augmentasi dan normalisasi data.) Teknik augmentasi ini akan secara acak memodifikasi citra (misalnya memutar atau menggeser letak objek) sehingga model lebih robust terhadap variasi kondisi input.

```
# ImageDataGenerator dengan augmentasi moderat
train_datagen = ImageDataGenerator(
    rescale=1.0/255,
    rotation_range=15,
    width_shift_range=0.2,
    height_shift_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode='nearest'
)

val_test_datagen = ImageDataGenerator(rescale=1.0/255)
```


Gambar 3. Kode Augmentasi dan Normalisasi

Gambar 3 menunjukkan kode augmentasi menggunakan ImageDataGenerator, yang secara acak memodifikasi gambar melalui rotasi, pergeseran, zoom, flipping horizontal, dan mengisi area kosong dengan metode `fill_mode='nearest'`.



Gambar 4. Sebelum dan Sesudah Augmentasi

- d. Normalisasi: Setelah augmentasi, citra juga dinormalisasi dengan mengubah nilai pikselnya ke skala 0–1 (dilakukan dengan parameter $\text{rescale}=1.0/255$ pada `ImageDataGenerator`). Normalisasi ini bertujuan memudahkan model dalam memproses data karena seluruh fitur berada pada skala yang relatif kecil dan seragam. (Gambar 4 menyajikan perbandingan histogram distribusi piksel sebelum dan sesudah normalisasi). Proses normalisasi pada `ImageDataGenerator` dengan $\text{rescale}=1.0/255$, yang secara otomatis membagi nilai piksel gambar dalam dataset dari rentang 0–255 menjadi 0–1 untuk mempermudah pemrosesan oleh model.



Gambar 5. Sebelum dan Sesudah Normalisasi

Histogram sebelum normalisasi menunjukkan distribusi nilai piksel dalam format aslinya, dengan nilai mayoritas berkisar antara 50 hingga 200. Setelah normalisasi, distribusi ini tetap sama dalam pola, tetapi skalanya berubah, dengan nilai piksel berkisar antara 0.2 hingga 1.0. Hal ini menunjukkan bahwa normalisasi berhasil menjaga pola distribusi piksel sambil memastikan semua nilai berada dalam skala yang lebih mudah diolah oleh model.

Dengan rangkaian tahapan di atas, dihasilkan data citra yang telah terlabeli, diubah ukurannya, serta diperbanyak variasinya melalui augmentasi dan dinormalisasi. Data inilah yang kemudian digunakan dalam proses pelatihan model CNN.

- Jumlah data yang digunakan dalam penelitian ini menggunakan 600 data, terdiri dari 300 data plastik dan 300 nonplastik, yang dibagi menjadi training (70%), validasi (15%), dan testing (15%) untuk memastikan model CNN dapat belajar dan dievaluasi dengan baik.
- Model CNN untuk klasifikasi sampah perairan terdiri dari beberapa lapisan konvolusi, pooling, dan fully connected layer untuk mengekstraksi fitur gambar. Dimulai dengan konvolusi 32 filter (3×3) dan ReLU, diikuti max pooling (2×2), lalu konvolusi 64 filter (3×3) dengan pooling, hingga 128 filter. Setelah flatten, data diproses oleh dense layer (128 neuron, ReLU), dropout untuk mencegah overfitting, dan softmax untuk klasifikasi plastik dan nonplastik.

Layer (type)	Output Shape	Param #
conv2d_3 (Conv2D)	(None, 222, 222, 32)	896
max_pooling2d_3 (MaxPooling2D)	(None, 111, 111, 32)	0
conv2d_4 (Conv2D)	(None, 109, 109, 64)	18,496
max_pooling2d_4 (MaxPooling2D)	(None, 54, 54, 64)	0
conv2d_5 (Conv2D)	(None, 52, 52, 128)	73,856
max_pooling2d_5 (MaxPooling2D)	(None, 26, 26, 128)	0
flatten_1 (Flatten)	(None, 86528)	0
dense_2 (Dense)	(None, 128)	11,075,712
dropout_1 (Dropout)	(None, 128)	0
dense_3 (Dense)	(None, 2)	258

Gambar 6. Model CNN

- c. Training model CNN dilakukan selama 50 epochs untuk mengenali pola dalam gambar dan membedakan sampah plastik serta nonplastik secara optimal.

```

Epoch 1/50
14/14 ————— 125s 9s/step - accuracy: 0.5006 - loss: 1.5586 - val_accuracy: 0.5667 - val_loss: 0.6615
Epoch 2/50
14/14 ————— 111s 8s/step - accuracy: 0.5915 - loss: 0.6593 - val_accuracy: 0.5000 - val_loss: 0.6756
Epoch 3/50
14/14 ————— 154s 9s/step - accuracy: 0.5932 - loss: 0.6534 - val_accuracy: 0.6222 - val_loss: 0.6262
Epoch 4/50
14/14 ————— 118s 8s/step - accuracy: 0.6308 - loss: 0.6221 - val_accuracy: 0.5778 - val_loss: 0.6414
Epoch 5/50
14/14 ————— 111s 8s/step - accuracy: 0.6660 - loss: 0.6325 - val_accuracy: 0.6556 - val_loss: 0.6033
Epoch 6/50
14/14 ————— 108s 8s/step - accuracy: 0.6687 - loss: 0.6139 - val_accuracy: 0.7000 - val_loss: 0.5950
Epoch 7/50
14/14 ————— 147s 8s/step - accuracy: 0.7156 - loss: 0.5809 - val_accuracy: 0.6778 - val_loss: 0.5832
Epoch 8/50
14/14 ————— 119s 8s/step - accuracy: 0.6795 - loss: 0.5967 - val_accuracy: 0.7444 - val_loss: 0.5522
Epoch 9/50
14/14 ————— 138s 8s/step - accuracy: 0.7441 - loss: 0.5850 - val_accuracy: 0.7000 - val_loss: 0.5503
Epoch 10/50
14/14 ————— 142s 8s/step - accuracy: 0.7017 - loss: 0.5880 - val_accuracy: 0.6667 - val_loss: 0.5262
Epoch 11/50
14/14 ————— 141s 8s/step - accuracy: 0.7626 - loss: 0.4945 - val_accuracy: 0.7556 - val_loss: 0.4843
Epoch 12/50
14/14 ————— 139s 8s/step - accuracy: 0.7418 - loss: 0.5248 - val_accuracy: 0.7667 - val_loss: 0.5028
Epoch 13/50
14/14 ————— 143s 8s/step - accuracy: 0.7749 - loss: 0.4946 - val_accuracy: 0.7667 - val_loss: 0.5304
Epoch 14/50
14/14 ————— 115s 8s/step - accuracy: 0.7229 - loss: 0.5382 - val_accuracy: 0.7111 - val_loss: 0.4971
Epoch 15/50

```

Gambar 7. Proses Training

- d. Evaluasi model dilakukan dengan data testing untuk mengukur akurasi model dalam mengklasifikasikan sampah plastik dan nonplastik setelah pelatihan.
- e. Hasil klasifikasi, merupakan output akhir dari model CNN setelah melalui seluruh tahapan.

3.2 Pengujian Model CNN

3.2.1 Distribusi kelas dataset

Dataset terdiri dari 600 gambar sampah bawah air yang dikategorikan sebagai plastik dan nonplastik, diperoleh dengan kamera GoPro Hero 11. Data dibagi menjadi training (70% – 420 gambar), validation (15% – 90 gambar), dan testing (15% – 90 gambar) untuk melatih, memvalidasi, dan menguji model.

3.2.2 Dataset gambar

Tabel 3 Data Plastik dan Nonplastik


No	Nama Objek	Kedalaman	Kategori
1.	Kemasan indomie 	60 cm	Plastik
2.	Botol Aqua 	80 cm	Plastik

No	Nama Objek	Kedalaman	Kategori
3.	Kaleng 	80 cm	Non plastik
4.	Sepatu 	80 cm	Non plastik
5.	Kaleng 	80 cm	Non plastik


Pada tabel 3 diatas merupakan contoh sampel yang digunakan dalam penelitian ini. Pemilihan data dilakukan agar data yang digunakan masih dapat dikenali oleh model agar dapat melakukan proses klasifikasi dengan baik.

3.3 Performa Model CNN

Hasil pelatihan model CNN ditampilkan pada Gambar 7(a) dan 7(b), grafik pertama menunjukkan kurva akurasi selama proses pelatihan, sedangkan grafik kedua menunjukkan kurva loss. Berdasarkan hasil ini, terlihat bahwa akurasi model meningkat secara bertahap seiring bertambahnya epoch, baik pada data training maupun validasi.



Gambar 8. (a)Accuracy




Gambar 8. (b) Loss

Model CNN yang dikembangkan berhasil dilatih selama 50 epoch dengan akurasi pelatihan dan validasi yang stabil. Pada akhir pelatihan, model mencapai akurasi sebesar 89% pada data uji. Grafik akurasi dan loss (Gambar 7(a) dan 7(b)) menunjukkan bahwa model mengalami peningkatan performa yang konsisten tanpa gejala overfitting yang signifikan.

Akurasi validasi stabil pada kisaran 75–77% pada epoch ke-50, sedangkan training accuracy meningkat hingga >85%. Loss validasi juga menurun secara bertahap hingga mendekati 0.5, menandakan proses pelatihan berjalan efektif.

3.4 Evaluasi Model

3.4.1 Confusion Matrix



Gambar 9. Confusion Matrix

Gambar 9 menunjukkan confusion matrix model, dengan 43 prediksi benar untuk nonplastik dan 37 untuk plastik. Kesalahan terjadi pada 2 nonplastik yang diklasifikasikan sebagai plastik dan 8 plastik sebagai nonplastik, menunjukkan model lebih sering keliru dalam mengenali sampah plastik.


3.4.2 Classification Report

Tabel 4 Classification Report

Kategori	Precision	Recall	F1-score	Support
Nonplastik	0.84	0.96	0.90	45
Plastik	0.95	0.82	0.88	45
Accuracy			0.89	90

Classification report menunjukkan akurasi model sebesar 89%, menandakan tingkat kesalahan yang relatif rendah. Untuk kelas nonplastik, precision 0.84, recall 0.96, dan F1-score 0.90, menunjukkan model lebih akurat dalam mengenali nonplastik. Sementara itu, untuk kelas plastik, precision lebih tinggi (0.95), tetapi recall lebih rendah (0.82), dengan F1-score 0.88, menandakan model masih kesulitan mengenali semua sampah plastik dengan benar.

3.5 Visualisasi Prediksi Model



Gambar 10. Hasil Prediksi

Gambar 10 menampilkan hasil prediksi model pada data uji. Pada gambar, terlihat bahwa model dapat mengenali sampah plastik seperti kantong plastik dan kemasan makanan, serta sampah non-plastik seperti kaleng dan objek lain yang bukan berbahan dasar plastik.

3.6 Pembahasan

Berdasarkan hasil pengujian, model CNN yang dikembangkan mampu mencapai akurasi 89%. Namun, masih terdapat beberapa kekeliruan dalam prediksi, terutama pada sampah plastik yang diklasifikasikan sebagai non-plastik. Hal ini kemungkinan disebabkan oleh:

- Kemiripan tekstur dan warna antara sampah plastik dan non-plastik, terutama di lingkungan bawah air dengan pencahayaan yang kurang optimal.
- Variasi bentuk dan posisi sampah, yang membuat model sulit mengenali pola dengan konsisten.
- Jumlah dataset yang terbatas, sehingga model belum sepenuhnya generalisasi untuk semua variasi sampah bawah air.

Berdasarkan hasil evaluasi, model CNN mampu mengklasifikasikan sampah bawah air dengan akurasi yang cukup baik, yaitu 89%. Meskipun demikian, terdapat beberapa keterbatasan yang perlu diperbaiki untuk meningkatkan performa model ke depannya. Perbaikan dapat dilakukan dengan menambah jumlah data, meningkatkan kompleksitas model, serta menerapkan teknik transfer learning.

Rekapan hasil uji model klasifikasi sampah bawah air berdasarkan pada Tabel 5:

Tabel 5 Data Uji

No	Data Uji	Kedalaman	Objek	Hasil Klasifikasi
1.	nonplastik 	80 cm	Sepatu	Non Plastik
2.	plastik 	30 cm	Kemasan air cup	Plastik
3.	nonplastik 	80 cm	Kaleng	Non Plastik
4.	plastik 	80 cm	Kemasan mie	Plastik

Setiap gambar dalam table Tabel 5 menampilkan objek sampah bawah air dengan label prediksi yang ditulis dalam warna berbeda. Label berwarna biru dengan tulisan "nonplastik" menunjukkan bahwa objek tersebut diklasifikasikan sebagai non-plastik, sedangkan label berwarna merah dengan tulisan "plastik" menunjukkan bahwa objek diklasifikasikan sebagai plastik. Dari data yang ditampilkan, sampah yang termasuk kategori plastik seperti kemasan air cup dan kemasan mie berhasil diklasifikasikan sebagai plastik, sedangkan sampah non-plastik seperti sepatu dan kaleng diklasifikasikan sebagai non-plastik. Pengambilan gambar dilakukan pada berbagai kedalaman, seperti 30 cm dan 80 cm.

4. KESIMPULAN

Berdasarkan hasil yang telah didapat dari pembahasan sebelumnya pada performa model CNN dalam klasifikasi sampah plastik dan non-plastik, dapat disimpulkan bahwa:

- Model CNN yang digunakan dalam klasifikasi sampah bawah air menunjukkan performa yang baik dengan akurasi sebesar 89%.
- Grafik akurasi dan loss menunjukkan tren yang stabil tanpa indikasi overfitting yang signifikan.
- Confusion matrix menunjukkan bahwa model lebih sering salah dalam mengklasifikasikan sampah plastik dibandingkan nonplastik, dengan 8 sampel plastik diklasifikasikan sebagai nonplastik.
- Berdasarkan classification report, precision untuk plastik lebih tinggi (0.95) dibandingkan nonplastik (0.84), tetapi recall plastik lebih rendah (0.82), yang berarti model cenderung lebih sulit mengenali sampah plastik.
- Secara keseluruhan, model memiliki keseimbangan yang baik dalam klasifikasi kedua kategori, tetapi masih bisa ditingkatkan terutama dalam mendeteksi sampah plastik dengan lebih baik.

5. SARAN

Beberapa saran yang dapat diberikan untuk pengembangan model di masa depan adalah:

- Mengumpulkan lebih banyak data sampah bawah air dengan berbagai variasi bentuk dan kategori yang digunakan.
- Melakukan optimasi hyperparameter seperti learning rate, batch size, dan jumlah epoch untuk meningkatkan akurasi model.
- Menggunakan model yang sudah dilatih sebelumnya dengan domain serupa meningkatkan akurasi tanpa memerlukan dataset dalam jumlah besar.

Dengan adanya penelitian ini, diharapkan metode CNN dapat berkontribusi dalam pengelolaan sampah bawah air dan menjadi bagian dari solusi inovatif dalam menjaga kelestarian lingkungan laut.

UCAPAN TERIMA KASIH

Penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada Bapak Imran Djafar, S.Kom., M.T., sebagai pembimbing I, serta Bapak Arwansyah, S.Kom., M.T., sebagai pembimbing II, atas bimbingan dan masukan berharga yang telah diberikan selama penyusunan jurnal ini. Selain itu, penulis juga mengapresiasi dirinya sendiri atas dedikasi dan kerja keras yang telah dicurahkan hingga jurnal ini dapat terselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] Hilmi, R. Z., Hurriyati, R., & Lisnawati. (2018). *IMPLEMENTASI CONVOLUTION NEURAL NETWORK (CNN) UNTUK KLASIFIKASI JAMUR KONSUMSI DI INDONESIA MENGGUNAKAN KERAS*. 3(2), 91–102.
- [2] Putri, O. N. (2020). Implementasi Metode CNN Dalam Klasifikasi Gambar Jamur Pada Analisis Image Processing (Studi Kasus: Gambar Jamur Dengan Genus Agaricus Dan Amanita). *Skripsi*, 1–80.
- [3] Rodriguez, Velastequí, M. (2019). Analisis Struktur Kovarians terhadap Indikator Kesehatan pada Lansia yang Tinggal di Rumah dengan Fokus pada Persepsi Kesehatan

- Subjektif. 1–23.
- [4] Fathoni Dwiatmoko, Utami, D., & Nuari Anisa Sivi. (2024). Klasifikasi Citra Sampah Organik dan Non Organik Menggunakan Algoritma CNN (Convolutional Neural Network). *Explore*, 14(1), 1–5. <https://doi.org/10.35200/ex.v14i1.103>
 - [5] Setiani, J. L. (2020). *Implementasi Convolutional Neural Network Dengan Arsitektur Resnet50 Untuk Identifikasi Jenis Sampah Plastik*.
 - [6] Ibnul Rasidi, A., Pasaribu, Y. A. H., Ziqri, A., & Adhinata, F. D. (2022). Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network. *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(1), 72–81. <https://doi.org/10.28932/jutisi.v8i1.4314>
 - [7] Anggraeni, K. N. (2024). Penerapan Convolutional Neural Network (CNN) untuk Klasifikasi Sampah dan Optimalisasi Sistem Penukaran Sampah. *JIMU: Jurnal Ilmiah Multi Disiplin*, 02(03), 3031–9498.
 - [8] Dewi, S., Ramadhani, F., & Djasmayena, S. (2024). Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network). *Hello World Jurnal Ilmu Komputer*, 3(2), 68–73. <https://doi.org/10.56211/helloworld.v3i2.518>
 - [9] Oktafiandi, H., & Winarnie, W. (2023). Implementasi Algoritma Convolution Neural Network pada Klasifikasi Limbah dengan Arsitektur MobileNet. *Prosiding Seminar Nasional Wijayakusuma National Conference*, 4(Vol. 4 No. 1 (2023): 4th Winco 2023), 97–106. <https://winco.cilacapkab.go.id>
 - [10] Stephen, Raymond, & Santoso, H. (2019). Aplikasi Convolution Neural Network Untuk Mendeteksi Jenis-Jenis Sampah. *Jurnal Sistem Informasi Dan Telematika*, Volume 10, 122–132.
 - [11] Irfansyah, D., Mustikasari, M., & Suroso, A. (2021). Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi. *Jurnal Informatika: Jurnal Pengembangan IT*, 6(2), 87–92. <https://doi.org/10.30591/jpit.v6i2.2802>
 - [12] Tilasefana, R. A., & Putra, R. E. (2023). Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG NET Untuk Pengenalan Cuaca. *Journal of Informatics and Computer Science (JINACS)*, 05(1), 48–57.