

Klasifikasi Sampah Laut Jenis Limbah Lastik Menggunakan Metode *Convolutional Neural Network Backpropagation* (Perairan Kota Tanjungpinang)

Hardi Prayuda¹⁾, Muhamad Radzi Rathomi²⁾, Novrizal Fattah Fahmitra³⁾

¹⁾²⁾³⁾ Program Studi Teknik Elektro dan Informatika, Fakultas Teknik dan Teknologi
Kemaritiman, Universitas Maritim Raja Ali Haji

Jl. Daeng Kamboja, Senggarang, Kec. Tj. Pinang Kota, Kota Tanjung Pinang

¹⁾ hardiprayuda2309@gmail.com

²⁾ radzi@umrah.ac.id

³⁾ nffahmitra@umrah.ac.id

Abstrak

Pencemaran laut akibat sampah plastik menjadi isu global, termasuk di Kota Tanjungpinang. Sampah plastik yang sulit terurai ini membahayakan ekosistem laut dan aktivitas manusia. Penelitian ini bertujuan untuk mengklasifikasikan jenis sampah plastik menggunakan metode CNN Backpropagation dengan arsitektur VGG-16 untuk meningkatkan efektivitas pengelolaan sampah. Dataset tersebut mencakup citra sampah laut dengan empat kelas sampah plastik: bungkus makanan, kantong plastik, botol plastik, dan bungkus minuman, beserta beberapa sampah non-plastik sebagai pembandingan. Model dilatih dengan ukuran *batch* 32 dan dievaluasi pada *epoch* 50 hingga 250. Performa terbaik dicapai pada *epoch* 250, dengan akurasi 97,66% dan *loss* 0,0798. Pengujian menghasilkan akurasi 93% untuk bungkus makanan, 93% untuk kantong plastik, 90% untuk botol plastik, 86% untuk bungkus minuman, dan 75% untuk sampah non-plastik. Model ini secara efektif mengklasifikasikan sampah plastik, mendukung pengelolaan sampah laut yang lebih baik di Kota Tanjungpinang.

Kata kunci: *CNN Backpropagation*, VGG-16, Klasifikasi Sampah Plastik Laut, Akurasi Data Uji.

Abstract

Marine pollution from plastic waste is a global issue, including in Tanjungpinang City. Plastic waste, which is hard to decompose, harms marine ecosystems and human activities. This study aims to classify plastic waste types using the CNN Backpropagation method with the VGG-16 architecture to improve waste management effectiveness. The dataset includes images of marine waste with four plastic waste classes: food wrappers, plastic bags, plastic bottles, and drink wrappers, along with some non-plastic waste for comparison. The model was trained with a batch size of 32 and evaluated at epochs 50 to 250. The best performance was achieved at epoch 250, with 97.66% accuracy and a loss of 0.0798. Testing yielded accuracies of 93% for food wrappers, 93% for plastic bags, 90% for plastic bottles, 86% for drink wrappers, and 75% for non-plastic waste. This model effectively classifies plastic waste, supporting better marine waste management in Tanjungpinang City.

Keywords: *CNN Backpropagation*, VGG-16, Classification of Marine Plastic Debris, Test Data Accuracy.

1. PENDAHULUAN

Sampah menjadi salah satu permasalahan rumit yang harus diselesaikan oleh suatu daerah yang berada dekat dengan daerah pesisir yang memiliki beberapa sungai yang bermuara ke laut [1]. Direktorat Pengendalian dan Kerusakan Pesisir Laut pada tahun 2017 melaporkan adanya 0,49 juta ton sampah plastik di laut Indonesia. Laporan Dinas Lingkungan Hidup Kota Tanjungpinang tahun 2022 menyatakan bahwa sampah plastik paling dominan di pesisir. Dalam

sehari, timbulan sampah mencapai 168 ton, dan 90 ton di antaranya merupakan sampah laut [2]. Dampak sampah plastik terhadap ekosistem laut sangat serius. Sampah ini dapat menggantikan sumber makanan, menguras biota laut, dan akhirnya menyebabkan kematian hewan laut [1]. Strategi pengelolaan sampah laut hingga kini masih dilakukan secara manual. Cara ini dianggap kurang efektif, sehingga diperlukan pembaruan untuk mengatasi permasalahan tersebut [3]. Metode *Convolutional Neural Network* (CNN) merupakan salah satu metode *deep learning* yang dapat digunakan untuk mendeteksi dan mengenali sebuah objek pada sebuah gambar digital [4]. Hasil penelitian sebelumnya dengan menggunakan metode ini dalam hal mengenali sampah cukup efektif dengan tingkat akurasi rata-rata diatas 85%, artinya model CNN ini dapat digunakan sebagai metode yang efektif dalam pengenalan sampah. Penelitian ini bertujuan untuk mengetahui keakuratan dari model CNN Backpropagation menggunakan arsitektur VGG-16 dalam hal mengenali sampah laut plastik di Kota Tanjungpinang.

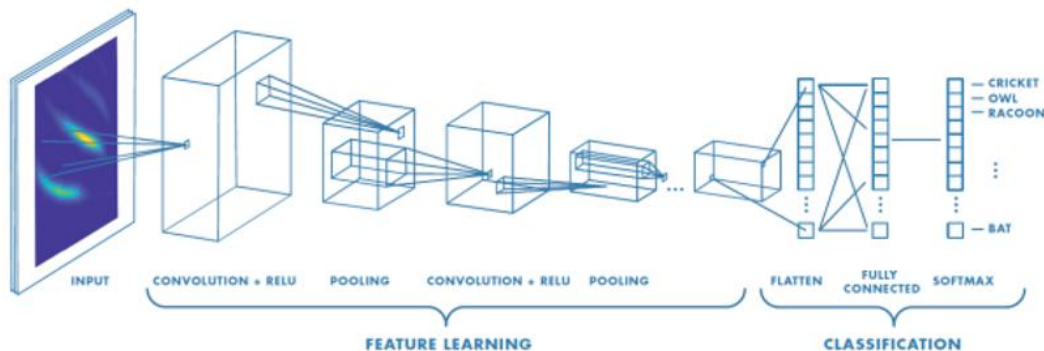
2. TINJAUAN PUSTAKA

2.1 Sampah Laut Plastik

Sampah laut (*marine debris*) adalah material sisa produk yang dibuang ke laut, baik secara sengaja maupun tidak. Sampah laut terdiri dari berbagai jenis limbah, namun perhatian utama tertuju pada plastik karena sulit terurai secara alami, tetapi perhatian utama terfokus pada limbah plastik karena sulit terurai secara alami. Ada berbagai macam bentuk plastik, seperti kantong plastik, botol, dan juga mikroplastik yang terbentuk dari degradasi plastik yang lebih besar [5].

2.2 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu algoritma deep learning yang dirancang untuk memproses data dua dimensi [6]. Convolutional Neural Network (CNN) adalah jaringan saraf tiruan feed-forward dengan struktur hierarkis. CNN mampu mempelajari representasi fitur internal dan menggeneralisasi berbagai masalah gambar, seperti pengenalan objek dan penglihatan komputer [7].



Gambar 1. Arsitektur *Convolutional Neural Network* (CNN)

2.2.1 Convolution Layer

Convolutional layer merupakan lapisan pertama dalam algoritma CNN. Lapisan ini berfungsi dengan cara melakukan sliding window pada input gambar. Convolution layer terdiri dari neuron yang membentuk filter dengan ukuran panjang dan tinggi (piksel) tertentu [8].

2.2.2 Rectified Linear Unit (REL-U)

Rectified Linear Unit (ReL-U) berfungsi untuk menerapkan fungsi aktivasi pada nilai output yang dihasilkan dari konvolusi pada convolution layer. Hasil dari fungsi aktivasi ini akan bernilai 0 (nol) jika inputnya negatif. Sebaliknya, jika inputnya positif, maka outputnya akan sama dengan nilai input dari fungsi aktivasi tersebut.

2.2.3 Pooling Layer

Pooling layer adalah komponen dalam feature learning pada CNN yang berfungsi untuk mengurangi dimensi matriks hasil konvolusi (convolved feature). Tujuan penggunaan pooling layer adalah untuk mempercepat proses komputasi.

2.2.4 Flatten

Flatten merupakan sebuah lapisan yang nantinya akan membentuk ulang fitur menjadi sebuah vektor agar bisa digunakan sebagai input dari Fully Connection. Tujuan dari proses flatten adalah untuk mengubah array multidimensi yang berupa feature map menjadi sebuah vektor satu dimensi.

2.2.5 Dropout Regularization

Dropout adalah teknik regularisasi dalam neural network di mana beberapa neuron dipilih secara acak untuk tidak digunakan selama proses pelatihan.

2.2.6 Fully Connected Layer

Fully-connected layer adalah komponen yang digunakan dalam penerapan multi-layer perceptron untuk mentransformasikan dimensi data, sehingga data tersebut dapat diklasifikasikan secara linier.

2.2.7 Softmax

Fungsi utama dari fungsi softmax dalam proses klasifikasi adalah untuk menghitung probabilitas setiap kelas target terhadap semua kelas yang ada.

2.3 Backpropagation

Backpropagation adalah metode penurunan gradien yang digunakan untuk meminimalkan kuadrat error dari output. Proses backpropagation terdiri dari tiga tahapan utama dalam pelatihan sistem, yaitu tahap perambatan maju (forward propagation), tahap perambatan belakang (backpropagation), dan tahap pembaruan bobot serta bias untuk mengurangi error yang diperoleh [9].

2.4 Arsitektur VGG-16

Arsitektur VGG-16 adalah model CNN dengan 16 lapisan konvolusi dan fully connected. Struktur ini memungkinkan ekstraksi fitur yang sangat abstrak dari gambar. Model ini memiliki dua aspek kunci, yaitu struktur arsitektur dan kedalaman lapisan konvolusinya. Penambahan kedalaman hingga 16 hingga 19 lapisan konvolusi menghasilkan perbaikan yang signifikan. Sebagai contoh, arsitektur VGG-16 terdiri dari 13 lapisan konvolusi, 2 lapisan fully connected, dan 1 lapisan klasifikasi [10].



Gambar 2. Arsitektur VGG-16

3. METODE PENELITIAN

Penelitian ini bertujuan untuk mengetahui tingkat akurasi model *Convolutional Neural Network* (CNN) dengan metode *backpropagation* dalam mengklasifikasikan sampah laut plastik. Data penelitian diperoleh dari wilayah pesisir Kota Tanjungpinang, yaitu Pelantar, Tanjung Unggat, dan Kampung Bugis. Citra sampah laut plastik diambil menggunakan kamera ponsel pribadi dengan total 500 gambar, terdiri atas botol plastik, bungkus makanan, bungkus minuman, dan kantong plastik. Dataset melalui tahap preprocessing berupa image cropping dan pelabelan

ke dalam empat kelas. Data kemudian dibagi menjadi 70% latih, 20% validasi, dan 10% uji. Proses pelatihan model CNN dilakukan menggunakan optimizer Adam dengan *learning rate* sebesar 0,001, *batch size* 32, serta penerapan *dropout* sebesar 0,5 untuk mengurangi *overfitting*. Evaluasi performa model dilakukan menggunakan confusion matrix pada data uji. Pengujian lanjutan memakai data citra baru: 30 gambar tiap kelas, 100 gambar sampah plastik acak, dan 20 gambar non-plastik. Akurasi dihitung dari jumlah prediksi benar dibandingkan total data uji.

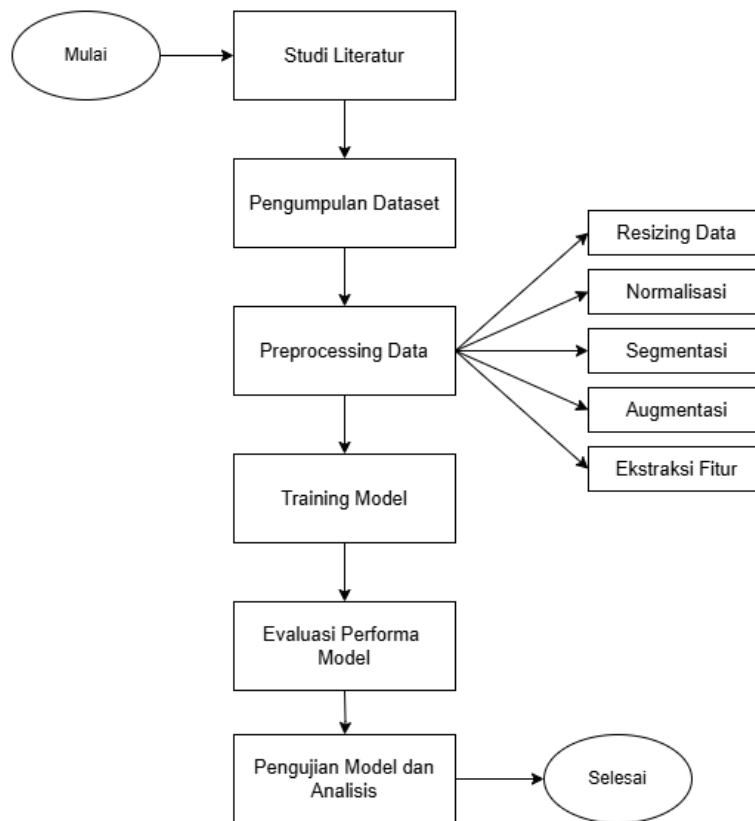
$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Objek Data}} \times 100\% \quad (1)$$

Keterangan:

Akurasi = Persentase prediksi model yang benar dibandingkan dengan total data pengujian (%).

Jumlah Prediksi Benar = Total prediksi model yang sesuai dengan label sebenarnya.

Total Objek Data = Jumlah keseluruhan data yang digunakan dalam evaluasi model.

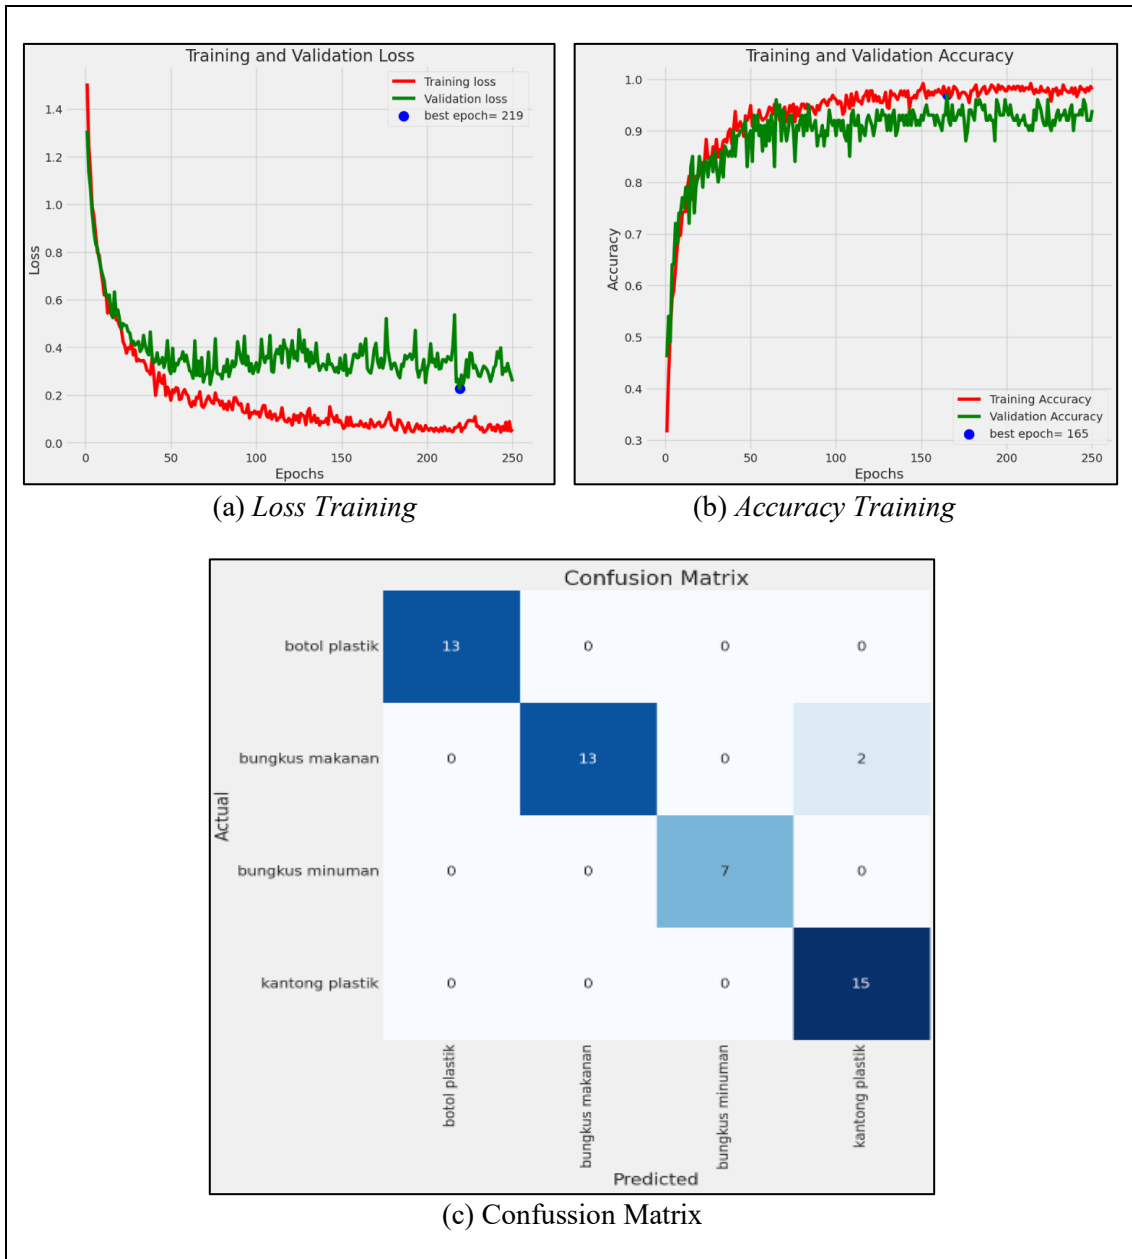


Gambar 3. Metode Penelitian

4. PEMBAHASAN

4.1 Pelatihan Algoritma CNN Backpropagation

Pada tahap ini dilakukan pelatihan model algoritma CNN Backpropagation menggunakan batch size 32. Pelatihan ini melibatkan penyesuaian beberapa parameter penting seperti optimizer, learning rate, dan dropout rate. Pelatihan model dilakukan sebanyak 250 epoch dalam waktu 1 jam 10 menit. Hasil akurasi pelatihan, loss, dan akurasi pengujian ditunjukkan pada Gambar 4.



Gambar 4. Hasil Pelatihan Model

Pada epoch ke-250, model menunjukkan performa optimal. Training loss sangat rendah, mendekati nol, menandakan model telah mempelajari pola data dengan baik. Validation loss juga rendah dan stabil, mencerminkan kemampuan generalisasi yang baik tanpa overfitting. Training accuracy melebihi 90%, dan validation accuracy mendekati angka tersebut, menunjukkan keseimbangan antara pelatihan dan validasi. Fluktuasi validation loss yang sebelumnya terlihat berhasil diminimalkan, mengindikasikan stabilitas model dalam memprediksi data baru. Stabilitas metrik loss dan akurasi menunjukkan parameter model telah dioptimalkan sepenuhnya. Epoch ke-250 menjadi titik terbaik pelatihan.

Dalam klasifikasi empat kelas sampah plastik, model menunjukkan performa yang beragam. Untuk kelas Botol Plastik, model memiliki presisi 0.94, recall 0.95, dan F1-score 0.94, menunjukkan kemampuan prediksi yang baik. Kelas Bungkus Makanan mencapai presisi 1.00, recall 0.96, dan F1-score 0.98, mencerminkan pengenalan sampel yang sangat baik. Kelas Bungkus Minuman memiliki presisi dan recall 0.88 dengan F1-score 0.88, menunjukkan

keseimbangan prediksi dan aktual. Kelas Kantong Plastik memiliki presisi 0.88, recall 0.95, dan F1-score 0.91, mencerminkan akurasi prediksi yang tinggi.

Dari keempat kelas, Bungkus Makanan dan Kantong Plastik memiliki performa terbaik, sedangkan Bungkus Minuman memiliki F1-score terendah, menandakan tantangan mengenali sampel kelas ini. Secara keseluruhan, model mencapai akurasi 0.93, menunjukkan kemampuan yang baik dalam mendeteksi dan mengklasifikasikan sampah plastik laut secara efektif.

Tabel 1. Hasil metrik evaluasi training model

| Jenis Sampah Plastik | Presisi | Recall | F1-Score | Akurasi |
|----------------------|---------|--------|----------|---------|
| Botol Plastik | 0.94 | 0.95 | 0.94 | 0.93 |
| Bungkus Makanan | 1.00 | 0.96 | 0.98 | |
| Bungkus Minuman | 0.88 | 0.88 | 0.88 | |
| Kantong Plastik | 0.88 | 0.95 | 0.91 | |

4.2 Pengujian Akurasi Pada Masing-Masing Kelas

Pada tahap ini, peneliti melakukan pengujian pada data baru untuk melihat seberapa akurat model yang telah dihasilkan sebelumnya. Tahap pengujian dilakukan pada 30 objek masing-masing kelas yaitu Botol Plastik, Bungkus Makanan, Bungkus Minuman, dan Kantong Plastik.

4.2.1 Botol Plastik

Tabel 2. Pengujian Dataset Botol Plastik

| Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi |
|---------------|---------------|---------------|---------------|---------------|---------------|
| Pengujian 1 | Benar | Pengujian 12 | Salah | Pengujian 23 | Benar |
| Pengujian 2 | Benar | Pengujian 13 | Benar | Pengujian 24 | Benar |
| Pengujian 3 | Benar | Pengujian 14 | Benar | Pengujian 25 | Benar |
| Pengujian 4 | Benar | Pengujian 15 | Benar | Pengujian 26 | Benar |
| Pengujian 5 | Benar | Pengujian 16 | Benar | Pengujian 27 | Benar |
| Pengujian 6 | Benar | Pengujian 17 | Benar | Pengujian 28 | Benar |
| Pengujian 7 | Salah | Pengujian 18 | Benar | Pengujian 29 | Benar |
| Pengujian 8 | Benar | Pengujian 19 | Salah | Pengujian 30 | Benar |
| Pengujian 9 | Benar | Pengujian 20 | Benar | | |
| Pengujian 10 | Benar | Pengujian 21 | Benar | | |
| Pengujian 11 | Benar | Pengujian 22 | Benar | | |

Perhitungan akurasi dalam menilai keakuratan model terhadap deteksi kelas Botol Plastik dihitung sebagai berikut menggunakan persamaan (1):

$$Akurasi = \frac{27}{30} \times 100\% = 90\%$$

4.2.2 Bungkus Makanan

Tabel 3. Pengujian dataset bungkus makanan

| Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi |
|---------------|---------------|---------------|---------------|---------------|---------------|
| Pengujian 1 | Benar | Pengujian 12 | Benar | Pengujian 23 | Benar |
| Pengujian 2 | Benar | Pengujian 13 | Benar | Pengujian 24 | Benar |
| Pengujian 3 | Benar | Pengujian 14 | Benar | Pengujian 25 | Benar |
| Pengujian 4 | Benar | Pengujian 15 | Benar | Pengujian 26 | Benar |
| Pengujian 5 | Salah | Pengujian 16 | Benar | Pengujian 27 | Benar |
| Pengujian 6 | Benar | Pengujian 17 | Benar | Pengujian 28 | Benar |
| Pengujian 7 | Benar | Pengujian 18 | Benar | Pengujian 29 | Benar |
| Pengujian 8 | Benar | Pengujian 19 | Benar | Pengujian 30 | Salah |
| Pengujian 9 | Benar | Pengujian 20 | Benar | | |
| Pengujian 10 | Benar | Pengujian 21 | Benar | | |
| Pengujian 11 | Benar | Pengujian 22 | Benar | | |

Perhitungan akurasi dalam menilai keakuratan model terhadap deteksi kelas bungkus makanan dihitung sebagai berikut menggunakan persamaan (1):

$$Akurasi = \frac{28}{30} \times 100\% = 93\%$$

4.2.3 Bungkus Minuman

Tabel 4. Pengujian dataset bungkus minuman

| Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi |
|---------------|---------------|---------------|---------------|---------------|---------------|
| Pengujian 1 | Benar | Pengujian 12 | Benar | Pengujian 23 | Benar |
| Pengujian 2 | Benar | Pengujian 13 | Benar | Pengujian 24 | Salah |
| Pengujian 3 | Benar | Pengujian 14 | Benar | Pengujian 25 | Salah |
| Pengujian 4 | Benar | Pengujian 15 | Benar | Pengujian 26 | Benar |
| Pengujian 5 | Benar | Pengujian 16 | Benar | Pengujian 27 | Salah |
| Pengujian 6 | Benar | Pengujian 17 | Benar | Pengujian 28 | Salah |
| Pengujian 7 | Benar | Pengujian 18 | Benar | Pengujian 29 | Benar |
| Pengujian 8 | Benar | Pengujian 19 | Benar | Pengujian 30 | Benar |
| Pengujian 9 | Benar | Pengujian 20 | Benar | | |
| Pengujian 10 | Benar | Pengujian 21 | Benar | | |
| Pengujian 11 | Benar | Pengujian 22 | Benar | | |

Perhitungan akurasi dalam menilai keakuratan model terhadap deteksi kelas bungkus minuman dihitung sebagai berikut menggunakan persamaan (1):

$$Akurasi = \frac{26}{30} \times 100\% = 86\%$$

4.2.4 Kantong Plastik

Tabel 5. Pengujian dataset kantong plastik

| Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi |
|---------------|---------------|---------------|---------------|---------------|---------------|
| Pengujian 1 | Benar | Pengujian 12 | Benar | Pengujian 23 | Benar |
| Pengujian 2 | Benar | Pengujian 13 | Benar | Pengujian 24 | Salah |
| Pengujian 3 | Benar | Pengujian 14 | Benar | Pengujian 25 | Benar |
| Pengujian 4 | Benar | Pengujian 15 | Benar | Pengujian 26 | Benar |
| Pengujian 5 | Benar | Pengujian 16 | Benar | Pengujian 27 | Benar |
| Pengujian 6 | Benar | Pengujian 17 | Benar | Pengujian 28 | Benar |
| Pengujian 7 | Benar | Pengujian 18 | Benar | Pengujian 29 | Benar |
| Pengujian 8 | Benar | Pengujian 19 | Benar | Pengujian 30 | Benar |
| Pengujian 9 | Benar | Pengujian 20 | Benar | | |
| Pengujian 10 | Benar | Pengujian 21 | Benar | | |
| Pengujian 11 | Salah | Pengujian 22 | Benar | | |

Perhitungan akurasi dalam menilai keakuratan model terhadap deteksi kelas kantong plastik dihitung sebagai berikut menggunakan persamaan (1):

$$Akurasi = \frac{28}{30} \times 100\% = 93\%$$

Berdasarkan hasil pengujian pada Tabel 2, 3, 4, dan 5, diketahui bahwa dari 30 objek pada masing-masing kelas, kelas bungkus makanan dan kantong plastik memiliki tingkat akurasi tertinggi, yaitu sebesar 93%, diikuti oleh kelas botol plastik dengan tingkat akurasi 90%, sedangkan kelas bungkus minuman menunjukkan tingkat akurasi paling rendah sebesar 86%. Hasil ini selaras dengan metrik evaluasi performa pada pelatihan model terbaik, yaitu model dengan epoch 250, di mana kelas bungkus makanan dan kantong plastik memiliki nilai performa yang lebih tinggi dibandingkan kelas lainnya. Akurasi rendah pada kelas bungkus minuman

diduga disebabkan oleh kemiripan pola visual dengan bungkus makanan. Faktor lain adalah material plastik tipis, variasi warna serupa, dan bentuk kemasan yang tidak konsisten. Kondisi citra di lingkungan pesisir juga memengaruhi hasil. Pencahayaan tidak merata, sudut pengambilan bervariasi, serta objek terlipat, kotor, atau rusak akibat air laut membuat model sulit mengekstraksi fitur pembeda secara optimal. Faktor lain yang berpotensi memengaruhi adalah ketidakseimbangan kompleksitas visual antar kelas serta keterbatasan variasi data pada kelas bungkus minuman, sehingga model cenderung mengalami kesulitan dalam membedakan fitur spesifik yang membedakan bungkus minuman dari bungkus makanan.

4.3 Pengujian Akurasi Pada Gambar Bukan Sampah Plastik

Tabel 6. Pengujian akurasi bukan sampah plastik

| Pengujian Ke- | Hasil Deteksi | Pengujian Ke- | Hasil Deteksi |
|---------------|---------------|---------------|---------------|
| Pengujian 1 | Benar | Pengujian 11 | Benar |
| Pengujian 2 | Benar | Pengujian 12 | Salah |
| Pengujian 3 | Benar | Pengujian 13 | Benar |
| Pengujian 4 | Benar | Pengujian 14 | Benar |
| Pengujian 5 | Benar | Pengujian 15 | Benar |
| Pengujian 6 | Benar | Pengujian 16 | Benar |
| Pengujian 7 | Salah | Pengujian 17 | Benar |
| Pengujian 8 | Benar | Pengujian 18 | Benar |
| Pengujian 9 | Benar | Pengujian 19 | Salah |
| Pengujian 10 | Salah | Pengujian 20 | Salah |

Perhitungan akurasi dalam menilai keakuratan model terhadap deteksi kelas kantong plastik dihitung sebagai berikut menggunakan persamaan (1):

$$Akurasi = \frac{15}{20} \times 100\% = 75\%$$

Berdasarkan hasil pengujian ini, terdapat 15 gambar yang terdeteksi benar bahwasanya gambar itu *undefined label* atau tidak terdeteksi sampah plastik dan 5 gambar salah terdeteksi bahwa sampah tersebut masuk di kategori kelas sampah plastik. Dapat dilihat pada gambar 5, gambar yang terdeteksi salah dari bentuk maupun pola visualnya hampir menyerupai botol plastik pada gambar (a) dan bentuk dari bungkus rokok menyerupai bungkus minuman pada gambar (b).



(a) Gambar terdeteksi botol plastik (b) Gambar terdeteksi bungkus minuman

Gambar 5. Pengujian Dataset Bukan Sampah Plastik

4.4 Pengujian Pengaruh Posisi Objek

Berdasarkan hasil pengujian dataset yang sama namun dengan posisi objek yang berbeda pada gambar 6 (a) hingga (d), model mampu mendeteksi beberapa objek dengan benar, namun juga terdapat sejumlah objek yang tidak terdeteksi atau salah klasifikasi. Hasil ini mencerminkan performa model dalam menghadapi tantangan deteksi objek pada lingkungan yang kompleks dan 137-variantive. Peneliti mengasumsikan pada hasil deteksi

yang benar menunjukkan bahwa model telah berhasil mengenali fitur visual khas dari beberapa kelas objek, seperti warna, tekstur, atau bentuk tertentu yang sudah dipelajari selama proses pelatihan. Namun, terdapat beberapa faktor yang menyebabkan model tidak dapat mendeteksi semua objek dengan benar. Salah satu faktornya adalah posisi objek yang berbeda pada setiap gambar.



Gambar 6. Pengujian Pengaruh Posisi Objek

5. KESIMPULAN

Hasil penelitian menunjukkan bahwa model CNN Backpropagation terbaik dicapai pada epoch 250 dengan training accuracy 97,66%, loss 0,798, dan accuracy confusion matrix 93%. Kelas yang paling mudah dikenali adalah bungkus makanan dengan recall 96%, diikuti kantong plastik dan botol plastik masing-masing 95%, serta bungkus minuman 88%. Pada pengujian dengan 100 data acak, model mencapai akurasi keseluruhan 91% untuk sampah plastik, sedangkan pada data non-plastik akurasi hanya 75%. Model menunjukkan performa baik dalam mengenali sampah laut plastik, terutama bungkus makanan dan kantong plastik. Peneliti menyimpulkan bahwa kegagalan deteksi dipengaruhi beberapa faktor. Faktor tersebut meliputi kualitas gambar, tumpukan objek, warna, kondisi perairan, kemiripan fitur antar kelas, pola atau teks khas, serta posisi objek. Hasil ini menunjukkan bahwa model CNN Backpropagation mampu mengklasifikasikan jenis sampah plastik di laut secara efektif, sehingga dapat mendukung pengelolaan sampah laut di Kota Tanjungpinang.

DAFTAR PUSTAKA

- [1] N. W. Ningsih, A. Putra, and H. Suriadin, "Identifikasi sampah laut berdasarkan jenis dan massa di perairan Pulau Lae-Lae Kota Makassar," *Jurnal Pengelolaan Perikanan Tropis*, vol. 4, pp. 10–18, 2020.
- [2] R. H. Subakti, "Implementasi penanganan sampah laut di Kota Tanjungpinang: Studi pada area perairan Teluk Keriting," Skripsi, Universitas Maritim Raja Ali Haji, Tanjungpinang, 2024.
- [3] S. Sofianto, "Peran Dinas Lingkungan Hidup dalam mengatasi pembuangan sampah sembarangan oleh masyarakat di Kota Tanjungpinang," *JRP: Jurnal Relasi Publik*, vol. 2, no. 1, 2024.

-
- [4] O. D. S. Sunanto and P. H. Utomo, "Implementasi deep learning dengan convolutional neural network untuk klasifikasi gambar sampah organik dan anorganik," in *Seminar Nasional Matematika, Geometri, Statistika, dan Komputasi*, vol. 377, 2022.
 - [5] Y. Johan, P. P. Renta, A. Muqsit, D. Purnama, L. Maryani, P. Hiriman, F. Rizky, and A. Fuji, "Analisis sampah laut (marine debris) di Pantai Kualo Kota Bengkulu," *Jurnal Enggano*, vol. 5, no. 2, pp. 273–289, 2020, doi: 10.31186/jenggano.5.2.273-289.
 - [6] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA: MIT Press, 2020.
 - [7] K. Ovtcharov, O. Ruwase, J.-Y. Kim, J. Fowers, K. Strauss, and E. S. Chung, "Accelerating deep convolutional neural networks using specialized hardware," *Microsoft Research Technical Report*, Feb. 2015. [Online]. Available: <https://www.microsoft.com/en-us/research/wp-content/uploads/2016/02/CNN20Whitepaper.pdf>.
 - [8] B. Raharjo, *Deep Learning dengan Python*. Semarang: Yayasan Prima Agus Teknik, 2022.
 - [9] K. Sandi, A. Prima, N. Dimas, and M. Arya, "Klasifikasi sampah menggunakan convolutional neural network," *Indonesian Journal of Data and Science (IJODAS)*, vol. 3, no. 2, pp. 72–81, 2022.
 - [10] A. Sudarsono, "Jaringan syaraf tiruan untuk memprediksi laju pertumbuhan penduduk menggunakan metode backpropagation (studi kasus di Kota Bengkulu)," *J. Media Infotama*, vol. 12, no. 1, pp. 61–69, 2020.
 - [11] D. F. Candra, G. Wibisono, M. F. Ayu, and M. Afrad, "Transfer learning model convolutional neural network menggunakan VGG-16 untuk klasifikasi tumor otak pada citra hasil MRI," *LEDGER: Journal Informatic and Information Technology*, vol. 3, no. 1, pp. 11–18, 2024.

Biodata Penulis

Novrizal Fattah Fahmitra, penulis merupakan dosen Program Studi Teknik Informatika di Universitas Maritim Raja Ali Haji. Penulis memperoleh gelar Sarjana Teknik Informatika di STMIK Amikom pada Tahun 2015 dan gelar Magister Informatika Medis di Universitas Islam Indonesia pada tahun 2023.

Hardi Prayuda, penulis merupakan lulusan Program Studi Teknik Informatika di Universitas Maritim Raja Ali Haji. Selama masa perkuliahan, penulis pernah menjadi salah satu bagian dari Program Kreativitas Mahasiswa bidang Pengabdian kepada Masyarakat.

Muhamad Radzi Rathomi, penulis merupakan dosen Program Studi Teknik Informatika di Universitas Maritim Raja Ali Haji. Penulis memperoleh gelar Sarjana Sistem Informasi di Universitas Lancang Kuning pada Tahun 2011 dan gelar Magister Ilmu Komputer di Universitas Gadjah Mada pada tahun 2015.