

## Klasifikasi Sampah Plastik di Laut Menggunakan Algoritma Faster R-CNN (Studi Kasus Tanjungpinang)

Novrizal Fattah Fahmitra<sup>1)</sup>, Farel Putra Albana<sup>2)</sup>, Muhamad Radzi Rathomi<sup>3)</sup>

<sup>1)2)3)</sup> Program Studi Teknik Informatika, Fakultas Teknik dan Teknologi Kemaritiman,  
Universitas Maritim Raja Ali Haji

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

<sup>1)</sup> nffahmitra@umrah.ac.id

<sup>2)</sup> farelputraalbana@gmail.com

<sup>3)</sup> radzi@umrah.ac.id

### Abstrak

Lingkungan global menghadapi tantangan serius berupa peningkatan sampah plastik, termasuk di Indonesia sebagai salah satu negara penghasil sampah plastik terbesar di dunia. Kota Tanjungpinang juga menghadapi permasalahan serupa dengan produksi sampah mencapai 100–150 ton per hari yang didominasi oleh sampah plastik. Sebagian besar sampah plastik tersebut berasal dari laut, sementara pengelolaannya masih terkendala oleh keterbatasan fasilitas dan teknologi. Sehingga diperlukan solusi pendeteksian sampah untuk meningkatkan efisiensi pengelolaan sampah plastik di wilayah tersebut. Penelitian ini bertujuan untuk mengukur akurasi performa model deteksi objek menggunakan bobot pra-latih algoritma Faster R-CNN dengan arsitektur ResNet-50 Feature Pyramid Network (FPN) sebagai backbone. Hasil eksperimen menunjukkan nilai  $mAP@0.50:0.95$  sebesar 59,55% dan  $mAP@0.50$  sebesar 82,64%. Pengujian pada masing-masing kelas sampah plastik menghasilkan akurasi sebesar 90% untuk botol plastik, 88% untuk bungkus makanan, 78% untuk bungkus minuman, dan 86% untuk kantong plastik. Hasil penelitian menunjukkan bahwa model pra-latih Faster R-CNN dengan backbone ResNet-50 FPN mampu mendeteksi dan mengklasifikasikan jenis sampah plastik di laut. Dengan demikian, model ini berpotensi membantu proses pengelolaan dan pemilahan sampah plastik di perairan Kota Tanjungpinang secara lebih efektif.

**Kata kunci:** Faster R-CNN, Model Pra-Latih, Klasifikasi Sampah Plastik,  $mAP$ , Akurasi Data Uji.

### Abstract

*The global environment is facing a serious challenge in the form of increasing plastic waste. Indonesia is one of the world's largest producers of plastic waste, and Tanjungpinang City faces a similar issue, generating approximately 100–150 tons of waste per day, predominantly plastic waste. A significant portion of this waste originates from marine environments, while its management remains limited by inadequate facilities and technological resources. Therefore, a waste detection solution is needed to improve the efficiency of plastic waste management in the region.. This study aims to evaluate the detection performance of a Faster R-CNN model using pre-trained weights with a ResNet-50 Feature Pyramid Network (FPN) backbone. Experimental results show an  $mAP@0.50:0.95$  of 59.55% and an  $mAP@0.50$  of 82.64%. Further evaluation for each plastic waste category resulted in accuracies of 90% for plastic bottles, 88% for food wrappers, 78% for beverage wrappers, and 86% for plastic bags. These findings indicate that the pre-trained Faster R-CNN model with a ResNet-50 FPN backbone is capable of effectively detecting and classifying different types of plastic waste in marine environments. Consequently, this model has the potential to support more effective waste management and sorting processes in the coastal waters of Tanjungpinang City.*

**Keywords:** Faster R-CNN, Pre-Trained Model, Floating Plastic Waste Classification,  $mAP$ , Test Data Accuracy.

## 1. PENDAHULUAN

Sampah plastik merupakan tantangan global yang sulit diatasi, termasuk di Indonesia yang menjadi salah satu penghasil sampah plastik terbesar dunia [1]. Sampah plastik sendiri dalam penguraiannya membutuhkan waktu hingga ratusan tahun, sehingga berpotensi mencemari lingkungan, terutama di perairan. Sampah plastik sering terbawa arus karena sifatnya yang ringan, mengancam ekosistem laut dengan melukai atau menyebabkan kematian organisme perairan akibat konsumsi plastik [2]. Kota Tanjungpinang di Provinsi Kepulauan Riau menghadapi masalah serupa dengan produksi sampah yang mencapai 100–150 ton per hari, di mana sampah plastik mendominasi. Data menunjukkan bahwa sekitar 1,2 ton sampah plastik berasal dari laut setiap hari [3]. Namun, pengelolaan sampah di Tanjungpinang kurang optimal karena keterbatasan fasilitas dan teknologi daur ulang [4]. Solusi berbasis teknologi, seperti deteksi dan klasifikasi sampah menggunakan metode pembelajaran mendalam, diharapkan dapat meningkatkan efisiensi pengelolaan sampah [5]. Metode seperti *Convolutional Neural Network* (CNN) telah terbukti efektif dengan akurasi mencapai 90% untuk deteksi jenis sampah [6]. Salah satu pengembangan dari metode ini yaitu *Faster R-CNN*, menawarkan akurasi tinggi sekaligus efisiensi waktu pemrosesan dengan mengeliminasi *selective search* [7]. Penelitian sebelumnya menunjukkan bahwa *Faster R-CNN* mampu menghasilkan akurasi tinggi untuk klasifikasi sampah, seperti 91,67% untuk kertas dan botol plastik [8]. Penelitian ini bertujuan untuk mengevaluasi performa algoritma *Faster R-CNN* dengan menggunakan *ResNet-50* FPN sebagai *backbone* ekstraksi fitur dalam melakukan klasifikasi jenis sampah plastik di laut kota Tanjungpinang. Fokus penelitian ini adalah mengklasifikasikan jenis sampah plastik yaitu botol plastik, bungkus makanan, bungkus minuman, dan kantong plastik. Diharapkan penelitian ini dapat membantu pengelolaan sampah plastik di perairan dengan mempermudah proses pemilahan sebelum didaur ulang.

## 2. TINJAUAN PUSTAKA

### 2.1 Sampah Plastik

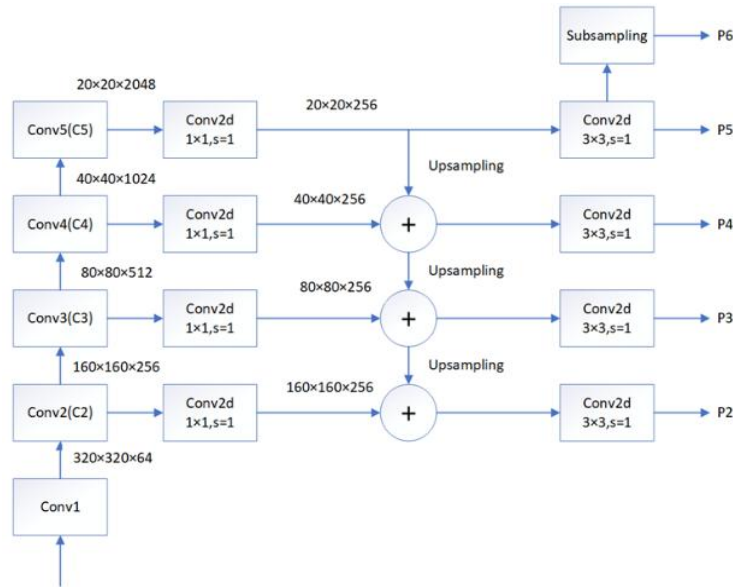
Salah satu masalah lingkungan yang umum terjadi di dunia adalah masalah sampah plastik. Sifat sampah plastik yang ringan, serbaguna, dan tahan lama menjadikannya sulit terurai secara alami jika dibiarkan di alam. Sampah plastik yang dibuang tanpa pemilahan membutuhkan waktu antara 100 hingga 500 tahun untuk terurai secara alami [9]. Proses penguraian sampah plastik menghasilkan partikel-partikel kecil yang disebut mikroplastik. Mikroplastik ini menimbulkan bahaya besar tidak hanya bagi biota laut tetapi juga manusia. Kontaminasi mikroplastik pada ikan laut berpotensi mempengaruhi kesehatan manusia melalui konsumsi ikan tersebut [10].

### 2.2 *ResNet-50* FPN

Deteksi objek merupakan salah satu bidang utama dalam visi komputer yang bertujuan untuk mengenali objek dalam gambar dan menentukan lokasinya. Model seperti *Faster R-CNN* yang menggunakan arsitektur jaringan saraf konvolusional sebagai *backbone* untuk ekstraksi fitur seperti *ResNet-50*, dikenal karena kedalamannya dan kemampuannya mengatasi masalah *vanishing gradient* melalui *residual learning* [11]. *ResNet-50* adalah bagian dari keluarga *Residual Network* (ResNet) yang menempati peringkat pertama dalam berbagai tugas seperti deteksi *ImageNet*, deteksi COCO, dan segmentasi COCO [12]. Arsitektur *ResNet-50* dirancang menggunakan pendekatan *residual learning*, yang memanfaatkan *shortcut connections* untuk memungkinkan informasi mengalir langsung melintasi lapisan tanpa terdegradasi dan mencegah kehilangan banyak informasi selama proses pelatihan [13]. Arsitekturnya terdiri dari 50 lapisan, termasuk elemen-elemen seperti *zero padding*, CNN, lapisan *max pooling*, lapisan aktivasi, dan lapisan yang terhubung penuh. *Hyperparameter* seperti ukuran gambar, jumlah *epoch*, optimizer, dan *batch size* disesuaikan untuk menghasilkan akurasi terbaik [11]. Sebagai model arsitektur dengan 50 lapisan, *ResNet-50* dirancang untuk menghasilkan akurasi yang tinggi [14]. Model ini telah dilatih sebelumnya pada lebih dari 1 juta gambar dari database *ImageNet* dan sangat baik dalam mengenali berbagai objek dan kategori [15].

*Feature Pyramid Network* (FPN) adalah arsitektur yang meningkatkan deteksi objek dengan mengekstrak peta fitur dari berbagai skala dan menyuplai informasi tersebut ke jaringan prediksi [16]. FPN terdiri dari dua jalur utama yaitu *Bottom-Up* sebagai ekstraksi fitur dari lapisan mendalam (detail tinggi) ke lapisan dangkal (detail rendah) dalam jaringan konvolusional dan *Top-Down* yang

menggunakan *upsampling* dan koneksi lateral untuk menggabungkan fitur dari jalur *Bottom-Up*, menghasilkan peta fitur beresolusi tinggi dengan konteks mendalam. FPN memanfaatkan *interpolasi bilinear* dan koneksi lompatan untuk menggabungkan peta fitur dari *encoder* dan *decoder*, memungkinkan deteksi objek kecil yang sulit ditangkap hanya dengan satu peta fitur skala [17].



Gambar 1. Struktur jaringan ResNet-50 dan FPN


### 2.3 Region Proposal Network (RPN)

*Region Proposal Network* (RPN) adalah metode deteksi objek berbasis pembelajaran mendalam yang bertujuan untuk melokalisasi wilayah kandidat yang kemungkinan mengandung sebuah objek dengan ciri-ciri terdiri dari sebuah jaringan kecil, yang digeser secara *sliding window* melintasi output dari lapisan konvolusi terakhir yang digunakan sebagai peta fitur [18]. RPN menggunakan jaringan saraf konvolusional untuk menghasilkan kotak pembatas (*bounding boxes*) yang relevan. RPN melaksanakan dua fungsi utama: klasifikasi biner untuk mendeteksi apakah area mengandung objek, dan regresi untuk memperbaiki kotak pembatas. Proses ini dibagi menjadi dua tahap: klasifikasi objek atau non-objek, dan regresi kotak batas. Dengan optimisasi yang tepat, RPN dapat meningkatkan akurasi deteksi objek secara signifikan [19].

### 2.4 Faster R-CNN

Algoritma *Faster R-CNN* adalah algoritma deteksi objek atau gambar yang menggabungkan *Region Proposal Network* (RPN) dengan *Convolutional Neural Network* (CNN) untuk mendeteksi dan mengklasifikasikan objek dalam gambar. Algoritma ini terdiri dari dua modul utama: yaitu RPN yang menghasilkan sekumpulan wilayah kandidat objek (*bounding boxes*) yang mungkin mengandung objek dan CNN yang mengklasifikasikan wilayah kandidat ini [18]. Kedua modul ini berbagi urutan lapisan konvolusi yang berfungsi sebagai ekstraktor fitur, dengan output lapisan konvolusi terakhir digunakan sebagai input bagi kedua modul tersebut. *Faster R-CNN* mengoptimalkan proses deteksi objek dengan menggantikan metode *Selective Search* yang digunakan pada R-CNN dan *Fast R-CNN* sebelumnya, memungkinkan deteksi objek dilakukan secara *end-to-end* dalam satu arsitektur [20].

Proses pelatihan *Faster R-CNN* dibagi menjadi empat tahap utama: pelatihan RPN, pelatihan *Fast R-CNN* menggunakan RPN, berbagi bobot antara RPN dan *Fast R-CNN*, serta pelatihan ulang *Fast R-CNN* dengan RPN yang diperbarui. RPN menggunakan dua jaringan, yaitu CNN yang dimodifikasi dengan lapisan konvolusi 3x3 dan ReLU untuk menghasilkan proposal wilayah, serta lapisan konvolusi 1x1 untuk regresi kotak yang menggunakan fungsi Smooth-L1. Tujuan utama dari pelatihan RPN adalah untuk mengurangi fungsi kerugian total, yang mencakup kerugian klasifikasi dan regularisasi, sehingga dapat meningkatkan efisiensi dan akurasi dalam deteksi objek [21].



Gambar 2. Arsitektur Faster R-CNN

### 3. METODE PENELITIAN

Penelitian ini bertujuan untuk mengukur akurasi metode Faster R-CNN dengan backbone ResNet-50 Feature Pyramid Network (FPN) dalam mendeteksi sampah plastik di perairan. Tahapan penelitian diawali dengan studi literatur untuk memperoleh referensi yang relevan. Dataset yang digunakan berjumlah 800 citra sampah plastik yang dikumpulkan dari enam lokasi di Kota Tanjungpinang, yaitu Tanjung Unggat, Pelantar II, Tepi Laut, Dompok, Pramuka, dan Senggarang. Pengambilan gambar dilakukan pada kondisi pencahayaan alami saat matahari tampak, meliputi pagi, siang, dan sore hari, dengan sudut pengambilan high angle dan eye level serta fokus pada sampah plastik yang terapung atau tampak di permukaan laut. Dataset selanjutnya diproses menggunakan Roboflow untuk pelabelan citra RGB dengan bounding box, penyesuaian ukuran dan orientasi gambar, serta pembagian data menjadi 80% data training dan 20% data testing dengan format COCO yang kompatibel dengan MMDetection. Proses pelatihan dilakukan menggunakan model pra-latih Faster R-CNN ResNet-50 FPN. Pemilihan parameter pelatihan seperti batch size dan jumlah epoch disesuaikan dengan keterbatasan sumber daya komputasi pada Google Colab untuk menjaga stabilitas proses pelatihan. Selama pelatihan, nilai *mean Average Precision (mAP)* digunakan sebagai metrik evaluasi dan dijadikan acuan pemilihan model terbaik [22], yang disimpan dalam bentuk file .pt. Tahap akhir penelitian adalah pengujian dan analisis model menggunakan data uji, termasuk data multilabel, untuk mengukur akurasi berdasarkan perbandingan antara jumlah prediksi benar dan total data uji [23]. Tahapan ini digunakan untuk menghitung akurasi berdasarkan jumlah prediksi benar dibandingkan total data menggunakan persamaan (1).

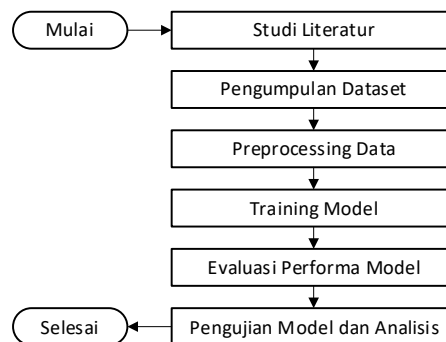
$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Objek\ Data} \times 100\% \quad (1)$$

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.

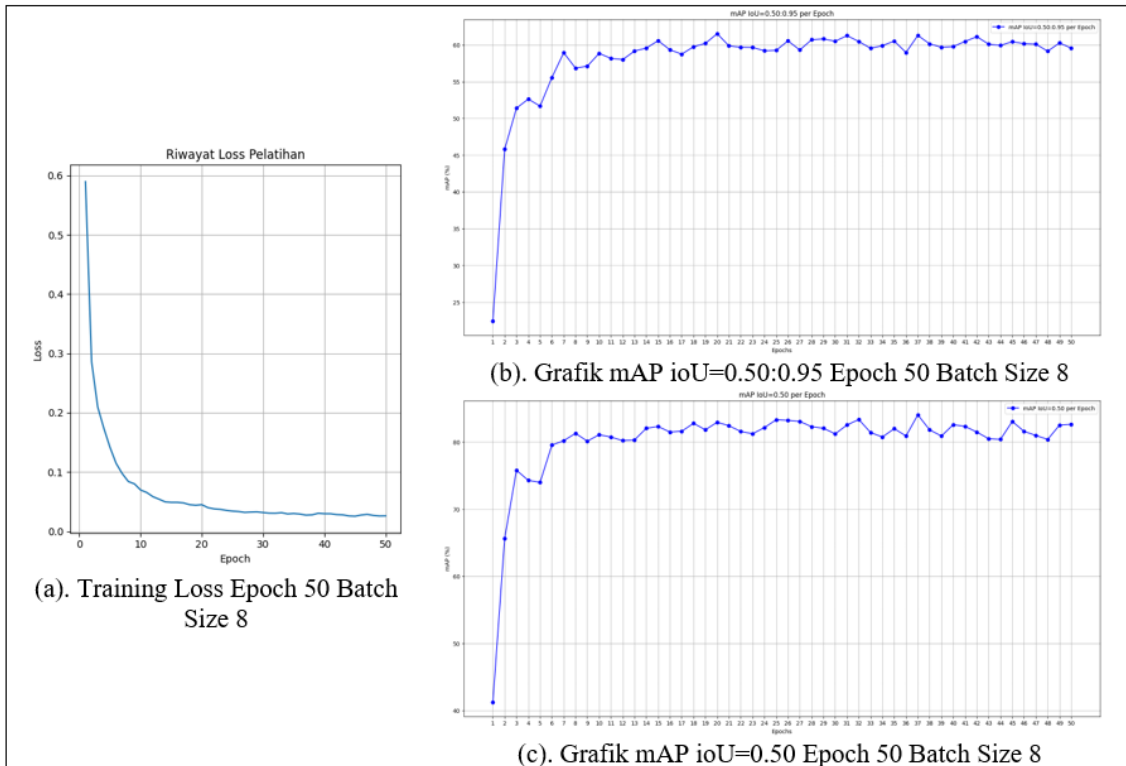


Gambar 3. Metode penelitian

#### 4. PEMBAHASAN

##### 4.1 Pelatihan Algoritma Faster R-CNN

Pada tahap ini, dilakukan pelatihan model algoritma *Faster R-CNN* menggunakan *batch size* sebesar 8. Pelatihan ini melibatkan penyesuaian berbagai parameter penting seperti optimizer, *learning rate*, momentum, dan *weight decay*. Peneliti melakukan pelatihan model sebanyak 50 *epoch* dalam waktu 2 jam 2 menit, yang di mana hasil loss dapat dilihat pada gambar 4.



Gambar 4. Hasil pelatihan model

Pada awal pelatihan nilai loss model cukup tinggi, karena model baru mulai belajar dan belum mengenali pola data. Seiring dengan bertambahnya *epoch*, nilai loss menurun signifikan hingga mencapai 0,1 pada *epoch* ke-20, menandakan model semakin memahami pola dalam data dan mampu memperbaiki kesalahannya. Setelah itu, grafik loss mulai mendatar, menunjukkan bahwa model telah mencapai kestabilan dengan perubahan nilai yang kecil pada setiap *epoch* berikutnya.

Evaluasi performa model menggunakan metrik *mAP* menunjukkan hasil yang lebih optimal pada *mAP@0.50* dibandingkan dengan *mAP@0.50:0.95*. Pada *mAP@0.50*, model mencapai *mAP* global sebesar 82,64%, menunjukkan akurasi yang sangat baik dalam mendeteksi dan mengklasifikasikan objek untuk sebagian besar kelas. Kelas Botol Plastik mencatat *mAP* tertinggi sebesar 94,19%, diikuti Bungkus Makanan dengan 83,32%. Kelas Kantong Plastik dan Bungkus Minuman masing-masing memiliki *mAP* sebesar 77,87% dan 75,19%, menunjukkan performa yang cukup kuat meskipun sedikit lebih rendah. Sebaliknya, evaluasi pada *mAP@0.50:0.95* menghasilkan *mAP* global lebih rendah, yaitu 59,55%. Hal ini disebabkan oleh rentang nilai IoU yang lebih ketat, yang menuntut prediksi model lebih presisi. Grafik *mAP* pada *mAP@0.50* menunjukkan peningkatan yang signifikan selama 10 *epoch* pertama, kemudian stabil di kisaran 80%-90%. Pada *mAP@0.50:0.95*, grafik memiliki pola serupa, tetapi dengan fluktuasi kecil dan stabil di kisaran 55%-60%. Fluktuasi ini disebabkan oleh perbedaan performa model dalam mendeteksi masing-masing kelas. Hasil ini menunjukkan bahwa model memiliki performa lebih baik pada standar toleransi overlap yang lebih rendah, tetapi membutuhkan penyempurnaan lebih lanjut untuk meningkatkan akurasi pada toleransi *overlap* yang lebih ketat.

Tabel 1. Hasil metrik evaluasi training model

No	Jenis Sampah Plastik	Nilai $mAP@0.50:0.95$	Nilai $mAp@0.50$
1	Botol Plastik	68,11%	94,19%
2	Bungkus Makanan	59,47%	83,32%
3	Bungkus Minuman	56,84%	75,19%
4	Kantong Plastik	53,79%	77,87%

## 4.2 Pengujian Akurasi Pada Dataset One Label

Pada tahap ini, peneliti melakukan pengujian pada data baru untuk melihat seberapa akurat model yang telah dihasilkan sebelumnya. Tahap pengujian dilakukan pada 50 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 (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)
Pengujian 1	Benar 1 (1)	Pengujian 12	Benar 1 (1)	Pengujian 23	Benar 1 (1)	Pengujian 34	Salah 1 (1)
Pengujian 2	Benar 1 (1)	Pengujian 13	Benar 1 (1)	Pengujian 24	Benar 1 (1)	Pengujian 35	Benar 1 (1)
Pengujian 3	Benar 2 (2)	Pengujian 14	Benar 1 (1)	Pengujian 25	Benar 1 (1)	Pengujian 36	Benar 2 Salah 1 (3)
Pengujian 4	Benar 1 (1)	Pengujian 15	Benar 1 (1)	Pengujian 26	Salah 1 (1)	Pengujian 37	Benar 1 (1)
Pengujian 5	Benar 1 (1)	Pengujian 16	Benar 1 (1)	Pengujian 27	Benar 1 (1)	Pengujian 38	Benar 1 (1)
Pengujian 6	Benar 1 (1)	Pengujian 17	Benar 1 (1)	Pengujian 28	Benar 2 (2)	Pengujian 39	Benar 1 (1)
Pengujian 7	Benar 1 (1)	Pengujian 18	Benar 1 (1)	Pengujian 29	Benar 1 (1)	Pengujian 40	Benar 1 (1)
Pengujian 8	Benar 1 (1)	Pengujian 19	Benar 1 (1)	Pengujian 30	Benar 1 (1)	Pengujian 41	Benar 1 (1)
Pengujian 9	Benar 1 (1)	Pengujian 20	Benar 1 (1)	Pengujian 31	Benar 2 Salah 1 (3)	Pengujian 42	Benar 1 (1)
Pengujian 10	Benar 1 (1)	Pengujian 21	Salah 1 (1)	Pengujian 32	Benar 1 (1)	Pengujian 43	Benar 1 (1)
Pengujian 11	Benar 1 (1)	Pengujian 22	Benar 1 (1)	Pengujian 33	Benar 1 (1)	Pengujian 44	Benar 1 (1)

Akurasi model terhadap deteksi kelas Botol =  $\frac{45}{50} \times 100\% = 90\%$ .

### 4.2.2 Bungkus Makanan

Tabel 3. Pengujian dataset bungkus makanan

Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)
Pengujian 1	Salah 1 (1)	Pengujian 15	Benar 1 (1)	Pengujian 29	Benar 1 (1)
Pengujian 2	Benar 1 (1)	Pengujian 16	Benar 1 (1)	Pengujian 30	Benar 2 (2)
Pengujian 3	Benar 2 (2)	Pengujian 17	Benar 1 (1)	Pengujian 31	Benar 1 (1)
Pengujian 4	Benar 1 (1)	Pengujian 18	Salah 1 (1)	Pengujian 32	Benar 1 (1)
Pengujian 5	Benar 1 (1)	Pengujian 19	Benar 1 (1)	Pengujian 33	Benar 1 (1)
Pengujian 6	Benar 1 (1)	Pengujian 20	Benar 1 (1)	Pengujian 34	Benar 1 (1)
Pengujian 7	Benar 1 (1)	Pengujian 21	Salah 1 (1)	Pengujian 35	Salah 1 (1)
Pengujian 8	Benar 1 (1)	Pengujian 22	Benar 2 (2)	Pengujian 36	Benar 1 (1)
Pengujian 9	Benar 2 (2)	Pengujian 23	Benar 1 (1)	Pengujian 37	Benar 1 (1)
Pengujian 10	Benar 5 (5)	Pengujian 24	Benar 1 (1)	Pengujian 38	Salah 1 (1)
Pengujian 11	Benar 1 (1)	Pengujian 25	Benar 1 (1)	Pengujian 39	Benar 1 (1)
Pengujian 12	Benar 1 (1)	Pengujian 26	Benar 1 (1)	Pengujian 40	Benar 1 (1)
Pengujian 13	Benar 1 (1)	Pengujian 27	Benar 1 (1)	Pengujian 41	Benar 1 (1)

Akurasi model terhadap deteksi kelas bungkus makanan =  $\frac{44}{50} \times 100\% = 88\%$ .

### 4.2.3 Bungkus Minuman

Tabel 4. Pengujian *dataset* bungkus minuman

Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)
Pengujian 1	Benar 1 (1)	Pengujian 11	Benar 1 (1)	Pengujian 21	Benar 1 (1)	Pengujian 31	Salah 1 (1)
Pengujian 2	Benar 1 (1)	Pengujian 12	Benar 1 (1)	Pengujian 22	Benar 1 (1)	Pengujian 32	Benar 3
Pengujian 3	Salah 2 (2)	Pengujian 13	Benar 1 (1)	Pengujian 23	Benar 1 (1)	Pengujian 33	Salah 2 (5)
Pengujian 4	Benar 1 (1)	Pengujian 14	Benar 1 (1)	Pengujian 24	Benar 1 (1)	Pengujian 34	Benar 1 (1)
Pengujian 5	Benar 1 (1)	Pengujian 15	Benar 1 (1)	Pengujian 25	Salah 1 (1)	Pengujian 35	Benar 3
Pengujian 6	Benar 1 (1)	Pengujian 16	Benar 1 (1)	Pengujian 26	Salah 1 (1)	Pengujian 36	Salah 1 (4)
Pengujian 7	Benar 1 (1)	Pengujian 17	Benar 1 (1)	Pengujian 27	Salah 1 (1)	Pengujian 37	Benar 1 (1)
Pengujian 8	Benar 1 (1)	Pengujian 18	Benar 1 (1)	Pengujian 28	Benar 1	Pengujian 38	Benar 1 (1)
Pengujian 9	Benar 1 (1)	Pengujian 19	Benar 1 (1)	Pengujian 29	Salah 1 (2)	Pengujian 39	Benar 1 (1)
Pengujian 10	Benar 1 (1)	Pengujian 20	Benar 1 (1)	Pengujian 30	Benar 2 (2)	Pengujian 40	Benar 1 (1)
					Salah 1 (1)		

Akurasi model terhadap deteksi kelas bungkus minuman =  $\frac{39}{50} \times 100\% = 78\%$ .

### 4.2.4 Kantong Plastik

Tabel 5. Pengujian *dataset* kantong plastik

Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)	Pengujian Ke-	Hasil Deteksi (Jumlah Objek)
Pengujian 1	Salah 1 (1)	Pengujian 11	Benar 1	Pengujian 21	Benar 1 (1)	Pengujian 31	Benar 1 (1)
Pengujian 2	Benar 4 (4)	Pengujian 12	Salah 1 (2)	Pengujian 22	Benar 2 (2)	Pengujian 32	Benar 1 (1)
Pengujian 3	Benar 1 (1)	Pengujian 13	Benar 1 (1)	Pengujian 23	Benar 1 (1)	Pengujian 33	Benar 2 (3)
Pengujian 4	Salah 1 (1)	Pengujian 14	Benar 1 (1)	Pengujian 24	Benar 1 (1)	Pengujian 34	Salah 1 (1)
Pengujian 5	Salah 1 (1)	Pengujian 15	Benar 1 (1)	Pengujian 25	Benar 1 (1)	Pengujian 35	Benar 1 (1)
Pengujian 6	Benar 1 (1)	Pengujian 16	Benar 1 (1)	Pengujian 26	Benar 1 (1)	Pengujian 36	Benar 1 (1)
Pengujian 7	Salah 1 (1)	Pengujian 17	Benar 1 (1)	Pengujian 27	Benar 1 (1)	Pengujian 37	Benar 1 (1)
Pengujian 8	Benar 1 (1)	Pengujian 18	Benar 1 (1)	Pengujian 28	Benar 2 (2)	Pengujian 38	Benar 3
Pengujian 9	Benar 1 (1)	Pengujian 19	Benar 1 (1)	Pengujian 29	Benar 1 (1)	Pengujian 39	Salah 1 (4)
Pengujian 10	Benar 1 (1)	Pengujian 20	Benar 1 (1)	Pengujian 30	Benar 1 (1)	Pengujian 40	Benar 1 (1)

Akurasi model terhadap deteksi kelas kantong plastik =  $\frac{43}{50} \times 100\% = 86\%$ .

Berdasarkan hasil pengujian pada Tabel 2, 3, 4, dan 5 bahwasanya dari 50 objek pada masing-masing kelas, tingkat akurasi kelas botol plastik paling tinggi mencapai 90%. Selanjutnya untuk kelas bungkus makanan, bungkus minuman, dan kantong plastik dengan akurasi masing-masing 88%, 78%, dan 86%. Hal ini sesuai dengan metrik evaluasi performa model pada pelatihan sebelumnya, di mana metrik evaluasi pada kelas botol plastik paling tinggi diantara kelas lainnya serta bungkus minuman yang rendah dikarenakan asumsi peneliti bahwa beberapa pola visual serta bentuk bungkus minuman yang menyerupai bungkus makanan.

### 4.3 Pengujian *Dataset Multi Label* dan Pengaruh Posisi Objek

Hasil pengujian pada *dataset multi label* dapat dilihat pada gambar 5 menunjukkan bahwa model mampu mendeteksi beberapa objek dengan benar, namun terdapat sejumlah objek yang tidak terdeteksi atau salah klasifikasi, terutama pada lingkungan yang kompleks dan variatif.

Deteksi yang benar menunjukkan kemampuan model mengenali fitur visual khas seperti warna, tekstur, atau bentuk tertentu. Namun, berbagai faktor memengaruhi akurasi deteksi, seperti pencahayaan yang tidak konsisten, bayangan, atau pantulan cahaya di permukaan air yang mengaburkan fitur visual pada objek. Selain itu, tumpukan objek atau posisi yang saling menutupi, serta kondisi objek yang terdegradasi, seperti warna memudar, kotor, atau tertutupi material lain, menjadi tantangan tambahan. Kemiripan fitur antar kelas juga memicu salah klasifikasi, di mana objek dengan karakteristik visual hampir sama sering kali terdeteksi secara keliru. Hasil ini menunjukkan bahwa model membutuhkan data pelatihan yang lebih beragam untuk mencakup variasi kondisi objek dalam situasi nyata guna meningkatkan akurasi deteksinya.



Gambar 5. Pengujian *dataset multi label*

Gambar 6 menunjukkan bahwa posisi objek memengaruhi keberhasilan model dalam mendeteksi dan mengklasifikasikan objek, terutama untuk kelas bungkus minuman. Gambar (c), objek bungkus minuman berhasil terdeteksi dengan tepat karena posisinya yang terbuka dan menonjol dari latar belakang, dengan bagian utama objek terlihat jelas, sehingga mempermudah model mengenali ciri khasnya, seperti warna atau pola. Sebaliknya, gambar (b), objek bungkus minuman tidak terdeteksi, karena orientasi objek menyembunyikan ciri khasnya, seperti tulisan atau pola unik. Gambar (a) dan (d), sistem mengklasifikasikan objek sebagai bungkus makanan, karena fitur visual seperti warna, pola, atau bentuk pada objek menyerupai karakteristik kelas bungkus makanan yang telah dipelajari oleh model. Hal ini menegaskan bahwa keberhasilan deteksi sangat bergantung pada kejelasan fitur visual yang ditampilkan oleh objek dalam gambar.



Gambar 6. Pengaruh posisi objek bungkus minuman

## 5. KESIMPULAN

Penelitian ini menunjukkan bahwa model Faster R-CNN mampu mendeteksi dan mengklasifikasikan sampah plastik di lingkungan laut dengan performa yang cukup baik. Pada epoch ke-50 dengan batch size 8, model mencapai nilai mAP@0.50:0.95 sebesar 59,55% dan mAP@0.50 sebesar 82,64%. Hasil pengujian pada data uji menunjukkan akurasi tertinggi pada kelas botol plastik sebesar 90%, diikuti oleh bungkus makanan sebesar 88%, kantong plastik sebesar 86%, dan bungkus minuman sebesar 78%. Evaluasi mAP per kelas juga memperlihatkan bahwa botol plastik memiliki performa terbaik dibandingkan kelas lainnya. Meskipun sebagian besar objek dapat terdeteksi dengan baik, masih ditemukan beberapa kesalahan deteksi dan objek yang tidak terdeteksi. Hal ini disebabkan oleh variasi pencahayaan, kondisi perairan, tumpukan objek, serta kemiripan karakteristik visual antar jenis sampah plastik. Namun demikian, hasil penelitian menunjukkan bahwa model pra-latih Faster R-CNN tetap mampu bekerja secara efektif pada kondisi perairan laut nyata. Kontribusi utama penelitian ini terletak pada penggunaan dataset sampah plastik yang dikumpulkan langsung dari perairan Kota Tanjungpinang dengan empat kelas, yaitu kantong plastik, botol plastik, bungkus makanan, dan bungkus minuman. Berbeda dengan penelitian sebelumnya yang umumnya menggunakan dataset hasil scraping atau lokasi terbatas, penelitian ini berfokus pada kondisi perairan laut nyata dengan konteks data lokal. Hasil penelitian menunjukkan bahwa Faster R-CNN efektif untuk mendeteksi sampah plastik di perairan laut dan berpotensi mendukung pengelolaan sampah di perairan Kota Tanjungpinang. Penelitian selanjutnya disarankan untuk memperluas variasi jenis sampah dan kondisi pengambilan gambar guna meningkatkan generalisasi model.

## DAFTAR PUSTAKA

- [1] S. Kaza, L. Yao, P. Bhada-Tata, and F. Van Woerden, *What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050*, Washington, DC, USA: World Bank Group, 2018.
- [2] L. Faizal, Y. Yuyun, and H. Hazriani, "Identifikasi sampah plastik menggunakan algoritma deep learning," *Jurnal Ilmiah Sistem Informasi dan Teknologi Informasi*, vol. 6, no. 2, pp. 162–171, 2023.
- [3] Sistem Informasi Pengelolaan Sampah Nasional (SIPSN), "Komposisi sampah," Kementerian Lingkungan Hidup dan Kehutanan, 2023. [Online]. Available: <https://sipsn.menlhk.go.id/sipsn/public/data/komposisi>.
- [4] S. Salsabila, E. Indrayanti, and R. Widiaratih, "Karakteristik mikroplastik di perairan Pulau Tengah, Karimunjawa," *Indonesian Journal of Oceanography*, vol. 4, no. 4, pp. 99–108, 2023.
- [5] A. I. Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi sampah organik dan non-organik menggunakan convolutional neural network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 1, pp. 142–149, 2022.
- [6] R. Adelia, N. Khairunisa, and R. Zulfiqri, "Implementasi convolutional neural network dalam mendeteksi sampah organik, plastik, dan kertas," *JUTIM (Jurnal Teknik Informatika Musirawas)*, vol. 9, no. 1, pp. 29–37, 2024.
- [7] S. T. E. Putri and A. Fahrurrozi, "Pendeteksian objek pada citra hewan karnivora dan herbivora menggunakan Faster R-CNN," *Jurnal Ilmiah Informatika Komputer*, vol. 27, no. 1, pp. 32–42, 2022.
- [8] D. M. Yafi and F. Utamingrum, "Sistem klasifikasi sampah perkantoran menggunakan metode Faster Region-Based Convolutional Neural Network berbasis NVIDIA Jetson Nano," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 7, pp. 3122–3127, 2022.
- [9] N. P. D. Arwini, "Sampah plastik dan upaya pengurangan timbulan sampah plastik," *Jurnal Ilmiah Vastuwidya*, vol. 5, no. 1, pp. 72–82, 2022.
- [10] A. Aulia, R. Azizah, L. Sulistyorini, and M. A. Rizaldi, "Literature review: Dampak mikroplastik terhadap lingkungan pesisir, biota laut, dan potensi risiko kesehatan," *Jurnal Kesehatan Lingkungan Indonesia*, vol. 22, no. 3, pp. 328–341, 2023.

- 
- [11] I. M. A. M. Dinata, I. G. A. Gunadi, and I. M. G. Sunarya, "Analisis hyperparameter pada klasifikasi jenis daging menggunakan algoritma convolutional neural network," *Jurnal Sains Komputer dan Informatika*, vol. 8, no. 1, pp. 25–34, 2024.
  - [12] S. Lasniari, J. Jasril, S. Sanjaya, F. Yanto, and M. Affandes, "Pengaruh hyperparameter convolutional neural network arsitektur ResNet-50 pada klasifikasi citra daging sapi dan daging babi," *Jurnal Nasional Komputasi dan Teknologi Informasi*, vol. 5, no. 3, pp. 474–481, 2022.
  - [13] F. Nashrullah, S. A. Wibowo, and G. Budiman, "The investigation of epoch parameters in ResNet-50 architecture for pornographic classification," *Journal of Computer Electronics and Telecommunications*, vol. 1, no. 1, pp. 1–8, 2020.
  - [14] J. Alberto and D. Hermanto, "Klasifikasi jenis burung menggunakan metode CNN ResNet-50," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 10, no. 3, pp. 34–36, 2023.
  - [15] D. A. Agustina, "Klasifikasi citra jenis kulit wajah dengan algoritma convolutional neural network ResNet-50," *Jurnal Riset Sistem Informasi*, vol. 1, no. 3, pp. 1–7, 2024.
  - [16] X. Pan, Z. Huan, Y. Li, and Y. Cao, "Enhancement of GUI display error detection using improved Faster R-CNN and multi-scale attention mechanism," *Applied Sciences*, vol. 14, no. 3, 2024.
  - [17] M. Islam and M. S. U. Yusuf, "Faster R-CNN-based traffic sign detection and classification," *WSEAS Transactions on Signal Processing*, vol. 18, pp. 1–10, 2022.
  - [18] L. W. Sommer, *Deep Learning-Based Vehicle Detection in Aerial Imagery*, Master's thesis, University of Twente, 2022.
  - [19] G. Seo, J. Yoo, and J. Choi, "KL-divergence-based region proposal network for object detection," in *Proc. International Conference on Artificial Intelligence*, pp. 1–5, 2020.
  - [20] M. F. Rahman and B. Bambang, "Deteksi sampah pada real-time video menggunakan metode Faster R-CNN," *Applied Technology and Computer Science Journal*, vol. 3, no. 2, pp. 117–125, 2021.
  - [21] G. A. Pratama, E. Y. Puspaningrum, and H. Maulana, "Convolutional neural network dan faster region convolutional neural network untuk klasifikasi kualitas biji kopi arabika," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, pp. 2776–2785, 2024.
  - [22] L. A. Darisang, S. K. Dwisetio, I. S. Edbert, and A. Aulia, "Real-time waste detection using YOLO, SSD, and Faster R-CNN integrated with CNN-based classification," in *Proc. Int. Conf. on Research and Innovations in Information and Engineering Technology (RITECH)*, 2025, pp. 76–83.
  - [23] M. Faisal, S. Chaudhury, K. S. Sankaran, S. Raghavendra, and others, "Faster R-CNN algorithm for detection of plastic garbage in the ocean: A case for turtle preservation," *\*Math. Probl. Eng.\**, vol. 2022, pp. 1–11, 2022.

### **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 Komputer bidang Informatika Medis di Universitas Islam Indonesia pada tahun 2023.

**Farel Putra Albana**, penulis merupakan mahasiswa lulusan di Universitas Maritim Raja Ali Haji pada program studi Teknik Informatika. Penulis pernah menjadi salah satu bagian dari Program Pertukaran Mahasiswa Merdeka Batch 4 di Universitas Dian Nuswantoro dan Program Kreativitas Mahasiswa bidang Pengabdian kepada Masyarakat tahun 2024.

**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 2016.