

## IMPLEMENTASI MASK R-CNN PADA PERHITUNGAN TINGGI DAN LEBAR KARANG UNTUK MEMANTAU PERTUMBUHAN TRANSPLANTASI KARANG

Naufal Alkhalis<sup>1</sup>, Husaini<sup>\*2</sup>, Haekal Azief Haridhi<sup>3</sup>, Cut Nadilla Maretina<sup>4</sup>, Nur Fadli<sup>5</sup>, Yudi Haditir<sup>6</sup>,  
Muhammad Nanda<sup>7</sup>, Maria Ulfah<sup>8</sup>, Kris Handoko<sup>9</sup>, Intan Malayana<sup>10</sup>, Arsa Cindy Safitri<sup>11</sup>

<sup>1,2,3,4,5,6,7,8,10,11</sup>Universitas Syiah Kuala, Banda Aceh

<sup>9</sup>Kementerian Kelautan dan Perikanan

Email: <sup>1</sup>husaini.muhammad@usk.ac.id, <sup>2</sup>naufal\_alk@mhs.usk.ac.id, <sup>3</sup>haekal.azief.haridhi@usk.ac.id,  
<sup>4</sup>cut\_nm@mhs.usk.ac.id, <sup>5</sup>nurfadli@usk.ac.id, <sup>6</sup>yudi@usk.ac.id, <sup>7</sup>m.nanda@usk.ac.id, <sup>8</sup>mariaulfah@usk.ac.id,  
<sup>9</sup>krishandoko.ahlimadya@gmail.com, <sup>10</sup>intanmalayana2003@gmail.com, <sup>11</sup>cindyarsa07@gmail.com

\*Penulis Korespondensi

(Naskah masuk: 26 Desember 2023, diterima untuk diterbitkan: 12 Juni 2024)

### Abstrak

Terumbu karang merupakan ekosistem yang berperan penting di laut serta sangat rentan terhadap kerusakan. Transplantasi karang telah menjadi salah satu pendekatan yang dilakukan untuk melestarikan terumbu karang. Pasca transplantasi, pemantauan perlu dilakukan untuk melihat pertumbuhan karang. Dalam upaya pemantauan, para penyelam harus membawa alat selam, penggaris dan buku untuk mengukur dan mencatat satu-satu karang yang telah ditransplantasi. Proses tersebut menghabiskan investasi finansial, waktu dan tenaga yang besar. Pemantauan dapat dioptimalkan dengan mengimplementasikan algoritma *Mask Region Convolutional Neural Network* (Mask R-CNN) melalui *library* Detectron2 pada citra transplantasi karang. Proses implementasi akan menghasilkan model yang dapat melakukan segmentasi pada objek karang. Segmentasi tersebut dapat dikalkulasikan untuk melihat tinggi dan lebar karang sebagai indikator pertumbuhan. Implementasi model melibatkan tujuh *backbone* segmentasi *instance* dengan jadwal laju pembelajaran sebesar tiga kali. Berdasarkan hasil penelitian, model yang dihasilkan telah berhasil diimplementasikan dalam mengukur tinggi dan lebar dari karang transplantasi. Perbandingan antara hasil pengukuran menggunakan model Mask R-CNN dan pengukuran langsung menunjukkan konsistensi yang baik. Dengan demikian para penyelam hanya perlu memaksimalkan sumberdaya yang dimiliki untuk mengambil citra karang dengan jarak yang telah ditentukan sehingga dapat meringkas waktu penyelaman.

**Kata kunci:** Terumbu Karang, Transplantasi, Mask R-CNN, Detectron2, Segmentasi, Pengukuran

## IMPLEMENTATION OF MASK R-CNN ON CORAL HEIGHT AND WIDTH CALCULATION TO MONITOR CORAL TRANSPLANT GROWTH

### Abstract

Coral reefs are ecosystems that play an important role in the sea and are very vulnerable to damage. Coral transplantation has become one of the approaches taken to preserve coral reefs. Post-transplant, monitoring needs to be done to see coral growth. In monitoring efforts, divers must carry diving equipment, rulers and books to measure and record the only corals that have been transplanted. The process consumes a huge investment of finance, time and effort. Monitoring can be optimized by implementing the *Mask Region Convolutional Neural Network* (Mask R-CNN) algorithm through the *Detectron2* library on coral transplant images. The implementation process will produce a model that can segment coral objects. The segmentation can be calculated to see the height and width of corals as growth indicators. The model implementation involves seven *backbone* segmentation instances with a learning rate schedule of three times. Based on the results of the study, the resulting model has been successfully implemented in measuring the height and width of transplanted corals. Comparison between measurement results using the Mask R-CNN model and direct measurements showed good consistency. Thus, divers only need to maximize their resources to take images of corals with a predetermined distance so as to shorten dive time.

**Keywords:** Coral Reef, Transplant, Mask R-CNN, Detectron2, Segmentation, Measurement

## 1. PENDAHULUAN

Terumbu Karang adalah ekosistem kompleks yang terbentuk oleh kerjasama antara biota pembentuk kapur dan endapan kalsium karbonat lainnya yang mendiami kedalaman laut dan juga bagian kolom air (Wong, Vrontos & Taylor, 2022). Terumbu karang memegang peranan penting dalam ekosistem laut, berfungsi secara fisik sebagai pemecah ombak dan secara ekologis sebagai habitat bagi berbagai biota laut (Rumkorem, Kurnia & Yulianda, 2019). Meskipun demikian, terumbu karang sangat rentan terhadap berbagai ancaman yang dapat menyebabkan gangguan pada ekosistemnya, baik yang bersifat global maupun lokal. Ancaman global muncul akibat perubahan kondisi bumi, seperti perubahan iklim dan pengasaman laut. Sementara itu, ancaman lokal berasal dari faktor-faktor di sekitar ekosistem terumbu karang, seperti pencemaran laut, penangkapan ikan yang merusak, dan aktivitas manusia lainnya yang dapat mengganggu kualitas hidup terumbu karang (Souter dkk, 2020).

Salah satu tindakan yang bisa diupayakan untuk mempertahankan kehidupan terumbu karang adalah melalui kegiatan transplantasi, guna memperbaiki dan memperluas ekosistem terumbu karang. Transplantasi karang merupakan metode sederhana yang dapat dilakukan untuk memulihkan kondisi terumbu karang yang rusak (Bukhari, Putra & Kurniawan, 2021). Dalam upaya transplantasi, konservasionis harus mengamati kemajuan dari karang yang telah di transplantasi. Namun, pengamatan pertumbuhan dari karang masih mengimplementasikan cara manual yang masih konvensional. Cakupan, skala, dan tingkat keberhasilan transplantasi umumnya hanya tersedia dalam studi ilmiah dan sebagian besar praktisi tidak memiliki kesempatan untuk membagikan kemajuan rehabilitasi karena keterbatasan yang ada (Ferse, Hein & Rölfer, 2021). Dalam upaya pengamatan, para penyelam harus membawa alat selam, penggaris dan buku untuk mengukur dan mencatat satu-satu karang yang telah ditransplantasi. Proses ini menghabiskan investasi finansial dan tenaga yang besar, terlebih kondisi arus laut, faktor cuaca, kondisi perairan, dan tingkat ketelitian yang tidak dapat diprediksi (Alamsyah dkk, 2019).

Untuk mengatasi tantangan tersebut, penggunaan *deep learning* menjadi solusi yang dapat diupayakan. Saat ini, berbagai kerangka kerja *deep learning* telah dikembangkan, salah satunya adalah algoritma *Mask Region Convolutional Neural Network* (Mask R-CNN). Mask R-CNN merupakan suatu arsitektur jaringan saraf tiruan yang dapat digunakan untuk tugas segmentasi *instance*. Segmentasi *instance* bertujuan memisahkan objek dan memberikan masker piksel untuk setiap objek yang ingin di pisah. Mask R-CNN mengadopsi pendekatan *two-stage object detection* yang tidak hanya melakukan segmentasi objek dengan *masking*, tetapi juga mengidentifikasi objek dengan *bounding box* (Budi, Haryanto & Setyati, 2023).

Masker piksel yang dihasilkan dimanfaatkan untuk melakukan perhitungan laju pertumbuhan karang transplantasi. *Bounding Box* yang dihasilkan juga dimanfaatkan untuk mengidentifikasi lokasi karang dalam citra mengingat kerapatan dari karang yang ditransplantasi. Melalui inovasi ini, konservasionis cukup memaksimal sumber daya yang dimiliki untuk mengambil foto terhadap karang transplantasi yang ingin diamati pertumbuhannya.

Penelitian ini akan menggunakan Algoritma Mask R-CNN yang terdapat dalam *library* Detectron2 yang dikembangkan oleh *Facebook Artificial Intelligence Research* (FAIR) yang mendukung berbagai tugas visi komputer, seperti segmentasi objek. Saat ini, *library* Detectron telah dikembangkan ke versi 2 yang lebih efisien (Akshayanivashini & Krisvan, 2023). Detectron2 memiliki berbagai fitur kunci, meliputi desain modular yang dapat dikembangkan, mendukung dataset dan model *custom*, serta memiliki kecepatan tinggi dalam proses pelatihannya. Detectron2 juga memiliki arsitektur *backbone* (tulang punggung) ResNet dan ResNeXt yang telah dilatih sebelumnya dengan menggunakan dataset besar, seperti ImageNet, untuk meningkatkan kemampuan deteksi dan segmentasi pada berbagai tugas visual (Pham, Pham & Dang, 2020). Keunggulan tersebut dinilai mampu mengatasi permasalahan keterbatasan waktu dan dataset yang dimiliki serta menjadikan langkah awal penerapan teknologi *deep learning* pada proses pemantauan pertumbuhan transplantasi karang.

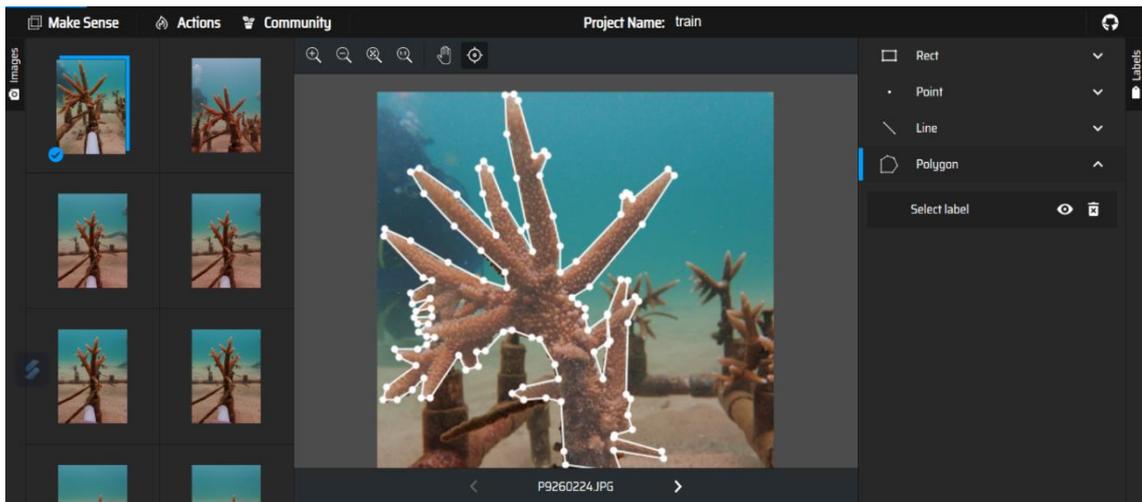
Oleh karena itu, penelitian ini tidak hanya bertujuan membawa keterbaruan dalam proses monitoring pertumbuhan karang pasca transplantasi, melainkan juga untuk memberikan kontribusi bagi para konservasionis dengan memangkas waktu mereka berada di bawah air. Dengan inovasi ini, para konservasionis hanya perlu menyelam untuk mengambil foto karang yang telah mereka transplantasi, dengan jarak yang sudah ditentukan melalui kamera, sehingga mengurangi kebutuhan akan pengukuran manual yang memakan waktu dan sumber daya yang lebih besar.

## 2. METODE PENELITIAN

Ada beberapa tahapan dalam mencapai tujuan penelitian. Berikut ini adalah langkah-langkah yang dilakukan pada penelitian ini.

### 2.1 Pengumpulan Dataset

Dataset yang digunakan diperoleh dari tempat pelaksanaan penelitian, dengan tujuan untuk menjamin bahwa data yang diterapkan memiliki keterkaitan langsung dengan konteks lingkungan di lokasi penelitian. Proses ini dilakukan selama 2 hari berdasarkan ketersediaan sumber daya yang dimiliki.



Gambar 2. Proses Anotasi

Dataset yang digunakan dalam riset ini mencakup sejumlah foto yang menggambarkan ekosistem transplantasi terumbu karang di wilayah perairan Pulau Gosong, yang terletak di Kecamatan Susoh, Kabupaten Aceh Barat Daya. Prosedur pengambilan foto dilakukan dengan memanfaatkan kamera dan sebuah tongkat yang telah dimodifikasi untuk mempertahankan jarak tetap 20 cm dari permukaan karang seperti pada Gambar 1.



Gambar 1. Tongkat Jarak

## 2.2 Pembagian Dataset

Pembagian dataset adalah proses membagi data menjadi beberapa bagian. Pembagian dataset dilakukan untuk mempartisi keseluruhan data agar dapat dilakukan proses lebih lanjut. Penelitian ini menerapkan pembagian dataset menjadi *subsets* pelatihan, validasi, dan pengujian. Setiap *subsets* masing-masing 80:10:10 untuk data pelatihan:validasi:pengujian.

## 2.3 Anotasi Dataset

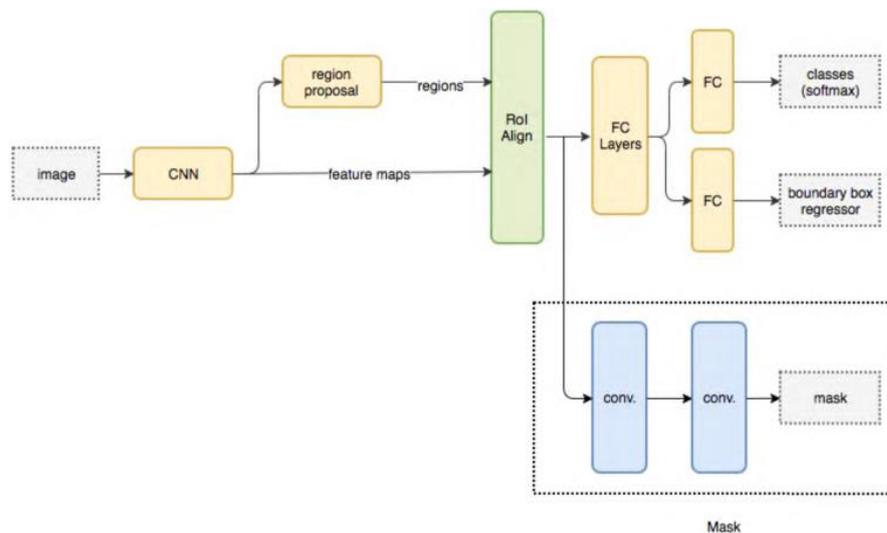
Algoritma segmentasi *instance*, seperti yang digunakan dalam penelitian ini, menggunakan format *Common Objects in Context* (COCO) sebagai data pelatihan untuk model (de Carvalho dkk, 2021). Proses pembangunan model sangat dipengaruhi oleh variasi gambar dalam dataset dan cara gambar-

gambar tersebut di anotasi dalam dataset (Sanusi, Fariza & Setiawardhana, 2023). Dataset yang sudah dipilah kemudian dipartisi ke dalam folder yang berbeda. Proses partisi data ke dalam folder masing-masing diikuti dengan proses anotasi ke dalam *file* metadata terpisah, yang mana terdapat dua *file* metadata terpisah untuk data pelatihan dan data validasi (de Carvalho dkk, 2021). Dalam penelitian ini, proses anotasi dilaksanakan menggunakan aplikasi anotasi makesense.ai. Penggunaan metode digitasi *polygon* digunakan untuk menentukan area *ground truth* pada citra. Untuk segmentasi *instance*, *mask polygon* digambar di sekitar area kelas yang dianggap sebagai objek pada setiap citra dalam dataset (Agnew dkk, 2023). Proses ini diterapkan pada seluruh data pelatihan dan data validasi, dan contoh proses anotasi dapat dilihat pada Gambar 2.

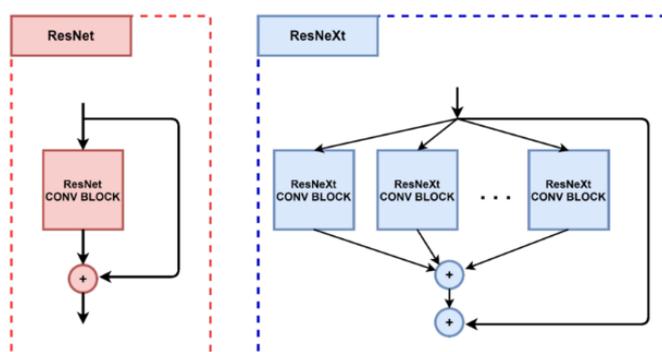
## 2.4 Implementasi Model

Berdasarkan ilustrasi Gambar 3, arsitektur Mask R-CNN diawali dengan memproses gambar masukan melalui sebuah *backbone* dalam lapisan CNN yang bertindak sebagai jaringan konvolusional. *Backbone* ini mengadopsi model ResNet dan ResNeXt sebagai jaringan *convolutional*. Melalui serangkaian operasi konvolusi pada tahap ini, fitur-fitur diekstraksi dari gambar masukan, menghasilkan apa yang disebut sebagai *feature map*. *Feature map* merupakan representasi visual dari hasil keluaran yang diperoleh dari lapisan-lapisan konvolusi dalam suatu jaringan saraf konvolusi.

Proses selanjutnya melibatkan *Region Proposal Network* (RPN) sebagai pendorong proposisi wilayah yang dianggap sebagai objek (*proposed region*). Pada tahap ini, *anchor* digunakan untuk mendapatkan wilayah yang dianggap sebagai objek, dan nilai IoU (*Intersection over Union*) digunakan untuk memastikan apakah suatu wilayah pada gambar masukan dianggap sebagai objek atau bukan.



Gambar 3. Arsitektur Mask R-CNN (Gonzalez, Arellano &amp; (Tapia, 2019)



Gambar 4. Ilustrasi ResNet dan ResNeXt

Setelahnya, *proposed region* yang dihasilkan pada *feature map* memasuki tahap *Region of Interest (RoI) Align*. Proses *RoI Align* bertujuan untuk mengekstraksi informasi fitur yang akan diteruskan ke *Fully Convolutional Network (FCN)*. FCN pada arsitektur Mask R-CNN memainkan peran ganda sebagai pengganti *Fully Connected Layer (FCL)* yang umumnya terdapat pada arsitektur lainnya. Ini karena FCN mampu mempertahankan informasi spasial dalam citra.

Tahap FCN menjadi langkah akhir dalam proses arsitektur Mask R-CNN, menghasilkan *output* yang melibatkan klasifikasi objek, kotak pembatas objek, dan segmentasi objek. Proses ini menggambarkan kompleksitas dan kedalaman pendekatan Mask R-CNN dalam menangani tugas deteksi dan segmentasi objek.

*Region Proposal Network (RPN)* melakukan pemeriksaan pada setiap titik pada *feature map* dengan tujuan menentukan keberadaan objek pada titik tersebut. Prediksi yang dihasilkan, yakni P5, P4, P3, dan P2, bertindak sebagai *feature map* yang diterapkan untuk menghasilkan *anchor boxes* atau proposal *bounding box*. Setelah proposal *bounding box* dihasilkan oleh RPN, tahap selanjutnya melibatkan penggunaan lapisan *RoI Align*. Lapisan

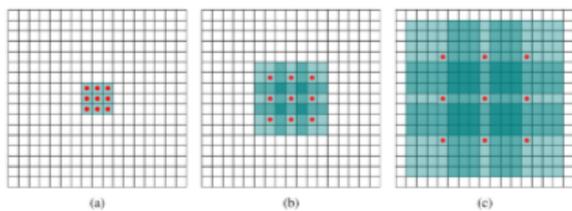
ini berfungsi untuk mengekstraksi fitur dari setiap proposal dengan tingkat presisi yang mencakup setiap piksel. Pentingnya RPN terletak pada kemampuannya menggunakan jaringan proposal wilayah untuk mengekstrak fitur, menciptakan dasar yang kuat untuk proses deteksi dan segmentasi objek lebih lanjut pada arsitektur Mask R-CNN.

Penelitian ini menggunakan algoritma Mask R-CNN dengan *backbone* dari arsitektur ResNet dan ResNext sudah disediakan pada model *baseline* segmentasi *instance COCO Detectron2*. ResNet dibangun untuk secara simultan menemukan jumlah lapisan yang dioptimalkan untuk mengatasi masalah hilangnya gradien (Ridhovan & Suharso, 2022). ResNeXt adalah perluasan ResNet dengan konsep *cardinality* untuk meningkatkan kapasitas representasi model, lebih efektif dan efisien daripada peningkatan lebar atau kedalaman seperti pada Gambar 4 (Zhou, Zhau & Wu, 2021).

Arsitektur *backbone* pada Detectron2 juga memiliki lapisan blok dan komponen yang berbeda-beda. *Backbone* tersebut terdiri dari ResNet50-C4, ResNet50-DC5, ResNet50-FPN, ResNet101-C4, ResNet101-DC5, ResNet101-FPN, ResNeXt101-FPN. ResNet-50 adalah arsitektur yang menggunakan 50 lapisan blok residen (*residual blocks*) dalam

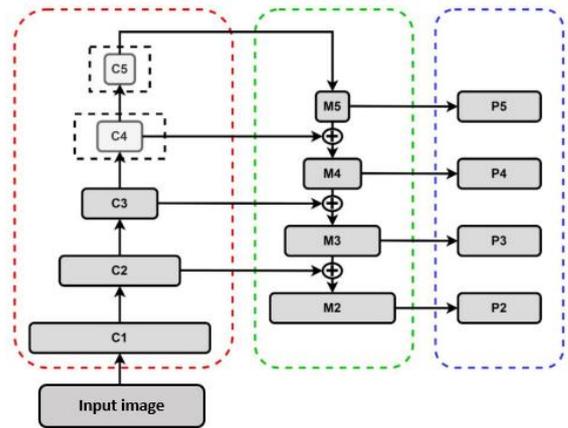
jaringannya (Ma, Li & Zhang, 2022). ResNet-101 adalah model yang lebih dalam dari ResNet-50, yang menggunakan 101 lapisan blok residen dalam jaringannya (Tahir, Iftikhar & Mumraiz, 2021). ResNext-101 memiliki struktur yang mirip dengan ResNet-101, tetapi memiliki blok yang lebih lebar dan ditandai dengan penggunaan parameter "cardinality," yang mengontrol ukuran *cardinality* jaringan (jumlah jalur dalam sebuah blok) (Vo dkk, 2019). Selain itu, setiap lapisan blok memiliki jumlah PARAMs dan *Floating Point Operations per Second* (FLOPs) yang berbeda.

Perbedaan lain dari ketujuh backbone yang digunakan adalah kombinasinya dengan komponen C4 (Conv-4), DC5 (Dilasi Conv-5) dan FPN (*Feature Pyramid Network*). Conv4 (C4) dalam arsitektur ResNet berperan sebagai lapisan konvolusi keempat yang mengekstraksi fitur semakin kompleks dari gambar. C4 menerapkan konvolusi pada representasi fitur yang telah dibentuk oleh blok residu sebelumnya, membantu model memahami pola dan fitur yang semakin kompleks. Peran penting C4 terletak pada kemampuannya menangani informasi yang kompleks dan abstrak, serta membantu model memahami konteks dan pola yang lebih mendalam. Dilasi pada DC5 merupakan proses penyisipan ruang di antara elemen-elemen filter konvolusional, memungkinkan filter memiliki bidang reseptif yang lebih besar tanpa meningkatkan jumlah parameter (Lei, Pam & Huang, 2019).



Gambar 5. Dilasi rate

Pada Gambar 5 merupakan proses Rekonstruksi dari ResNet yang berdilatasi mirip dengan ResNet aslinya, kecuali langkah *max pooling* dihapus dan digantikan oleh penggunaan operasi *pooling*, sementara dilatasi diterapkan pada blok konvolusi 5. FPN menjadi yang digunakan dalam *backbone* untuk mengatasi tantangan variasi skala. Pada Gambar 6, struktur *bottom-up* tergambar dengan jelas pada garis putus-putus merah, sementara bagian *top-down*, yang berperan sebagai ekstraktor fitur, menunjukkan keberadaan empat modul (M5, M4, M3, dan M2). Setiap modul ini mengalami lipatan ganda dari satu modul ke modul berikutnya. Selain sebagai ekstraktor fitur, setiap modul pada bagian *top-down* memberikan prediksi (P5, P4, P3, P2).



Gambar 6. Feature Pyramid Network (FPN)

Prediksi ini nantinya akan digunakan dalam RPN, mengilustrasikan kompleksitas dan keterkaitan antar bagian pada arsitektur keseluruhan.

### 2.5 Analisis Model

Model yang sudah dilatih dengan ketujuh *backbone* kemudian di evaluasi. Evaluasi didapatkan berdasarkan hasil prediksi model terhadap data validasi yang sudah dilakukan. Dalam konteks model segmentasi *instance*, dua metrik utama yang diperhatikan adalah presisi (Persamaan (1)) dan recall (Persamaan (2)). Presisi mengukur jumlah *instance positif* yang diidentifikasi dengan benar (TP) dibagi oleh total prediksi yang positif (TP + FP), sementara *recall* mengukur jumlah *instance positif* yang diidentifikasi dengan benar (TP) dibagi oleh total jumlah *instance positif* yang seharusnya terdeteksi (TP + FN).

$$presisi = \frac{TP}{(TP+FP)} \tag{1}$$

$$recall = \frac{TP}{(TP+FN)} \tag{2}$$

Analisis model juga dilakukan pada pengamatan terhadap perbandingan antara waktu pelatihan dan waktu inferensi model guna mendapatkan pemahaman yang lebih komprehensif.

### 2.6 Menghitung Laju Pertumbuhan Karang

Dalam penelitian ini, proses pemantauan pertumbuhan karang transplantasi dilakukan melalui parameter panjang dan lebar, dengan perhitungan dilakukan melalui area masker yang menutupi seluruh objek yang dianggap sebagai karang dalam citra. Proses perhitungan ukuran karang dilakukan pada *threshold* 0,9 setelah dilakukan percobaan penyesuaian, yang menghasilkan segmentasi terbaik di antara seluruh percobaan yang dilakukan. Hal ini dilakukan agar visualisasi dari segmentasi karang tidak lebih dari satu, memastikan keakuratan dan konsistensi dalam analisis pertumbuhan karang. Proses perhitungan dilakukan dengan cara mengambil satu sampel citra karang yang sudah terukur langsung dengan alat pengukur dalam satuan sentimeter (cm). Proses perhitungan tinggi

(Persamaan (3)) dilakukan dengan cara mencari terlebih dahulu jumlah piksel  $y$  maksimum dan  $y$  minimum kemudian dikurangi. Proses perhitungan lebar (Persamaan (4)) dilakukan dengan cara mencari terlebih dahulu jumlah piksel  $x$  maksimum dan  $x$  minimum kemudian dikurangi.

$$tinggi_{piksel} = y_{maks} - y_{min} \quad (3)$$

$$lebar_{piksel} = x_{maks} - x_{min} \quad (4)$$

Setelah nilai tinggi dan lebar objek masker karang diperoleh kemudian dihitung nilai faktor konversi tinggi dan lebar. Proses ini dilakukan dengan cara membagi nilai tinggi (Persamaan (5)) dan lebar (Persamaan (6)) karang sebenarnya yang telah diukur dengan nilai tinggi dan lebar karang dalam satuan piksel. Proses ini dilakukan agar bisa diimplementasikan ke citra karang lain dan proses perhitungan tinggi dan lebar pada persamaan (3) dan persamaan (4) dalam piksel tidak perlu dilakukan lagi.

$$konversi_{tinggi} = \frac{tinggi_{cm}}{tinggi_{piksel}} \quad (5)$$

$$konversi_{lebar} = \frac{lebar_{cm}}{lebar_{piksel}} \quad (6)$$

Setelah nilai faktor konversi tinggi dan lebar diperoleh, kemudian dihitung nilai tinggi dan lebar sebenarnya dalam satuan sentimeter. Proses untuk mencari nilai tinggi dilakukan dengan cara mengalikan hasil nilai yang diperoleh pada persamaan (3) dengan persamaan (5), sedangkan untuk mencari nilai lebar dilakukan dengan cara mengalikan hasil nilai yang diperoleh pada persamaan (4) dengan persamaan (6). Seperti pada persamaan (7) dan persamaan (8) di bawah.

$$tinggi_{cm} = tinggi_{piksel} \times konversi_{tinggi} \quad (7)$$

$$lebar_{cm} = lebar_{piksel} \times konversi_{lebar} \quad (8)$$

### 3. HASIL DAN PEMBAHASAN

Data yang menjadi subjek penelitian ini diperoleh melalui metode pengambilan foto yang dilakukan secara langsung di lokasi transplantasi terumbu karang, sesuai dengan lokasi penelitian. Pendekatan ini dipilih dengan sengaja untuk memastikan bahwa model yang dikembangkan memiliki keterkaitan yang erat dengan keadaan sebenarnya di perairan sekitar Pulau Gosong, Aceh Barat Daya. Kamera yang mengambil objek karang di atur sedemikian rupa hingga dapat menghasilkan dimensi 3000x4000 piksel. Secara keseluruhan terdapat 570 citra dalam dataset yang berhasil diperoleh. Beberapa contoh hasil pengambilan foto karang juga ditunjukkan pada Gambar 7. Foto-foto ini merupakan representasi visual dari data yang digunakan dalam penelitian ini, memberikan gambaran lebih lanjut terkait kondisi dan karakteristik karang yang menjadi fokus.



Gambar 7. Sampel Foto Dataset

Dari total 570 foto yang berhasil dikumpulkan, sebanyak 447 foto dipilih sebagai data pelatihan, memungkinkan model untuk memahami dengan efektif pola-pola kompleks dalam dataset tersebut. Evaluasi kinerja dilakukan melalui data validasi yang terdiri dari 47 foto. Kemudian, sebanyak 47 foto digunakan untuk menguji kehandalan model di luar konteks pelatihan seperti pada Tabel 1. Hasil yang diperoleh dapat dianggap sebagai representasi yang andal dan dapat diaplikasikan secara efektif dalam konteks penerapan pada ekosistem transplantasi terumbu karang di perairan Pulau Gosong, Aceh Barat Daya.

pembagian data	jumlah Foto
Pelatihan	476
Validasi	47
Pengujian	47

Anotasi dilakukan dengan menggunakan *annotator makesense.ai* dengan memanfaatkan *annotator polygon* kemudian dilakukan pemilihan area objek karang pada foto. Anotasi dilakukan pada seluruh data pelatihan dan validasi dengan disertai penambahan label *coral* untuk objek karang yang di anotasi. Anotasi dilakukan pada seluruh objek karang yang terdapat pada setiap foto. Tujuan dilakukan anotasi dataset adalah memilih area *ground truth* pada foto yang akan dikirim menjadi data dalam format *file COCO JavaScript Object Notation (JSON)* yang berisi informasi terstruktur tentang dataset. Informasi yang terdapat dalam *file* ini yaitu terdiri dari informasi terkait id objek, label kelas objek, dan koordinat objek. Proses anotasi ini bertujuan untuk memberikan dasar data yang akurat dan terstruktur bagi model yang akan digunakan. Hasil dari anotasi ini kemudian disatukan ke dalam folder pelatihan dan validasi yang telah di partisi sebelumnya.

Pelatihan model dimulai dengan melakukan *register* dataset dengan menggunakan fungsi yang telah disediakan oleh *library Detectron2*. *Register* dilakukan bertujuan agar dapat dilakukan tahapan selanjutnya untuk pelatihan model. *Register* dilakukan dengan memuat lokasi direktori data pelatihan dan COCO JSON yang telah dilakukan anotasi. Tahap ini dilakukan pada kedua dataset pelatihan dan validasi.

Pada tahap pelatihan model juga dilakukan konfigurasi *hyperparameter* yang digunakan selama proses pelatihan menggunakan tujuh *backbone*. Konfigurasi dilakukan pada masing-masing *backbone* dengan pengaturan yang sama pada setiap *backbone*. Konfigurasi *hyperparameter* meliputi penentuan tingkat pembelajaran (*learning rate*) saat dilakukan pelatihan, pengaturan jumlah iterasi yang digunakan, jumlah *RoI (Region of Interest) Heads* yang digunakan dalam setiap foto, pengaturan jumlah kelas yang menjadi label pada data dan jumlah pekerja (*workers*) untuk memuat data. Penyesuaian *hyperparameter* dilakukan sehingga menemukan konfigurasi yang paling baik untuk diterapkan pada setiap pelatihan model. Dilakukan beberapa percobaan dan pelatihan agar dapat menghasilkan model dengan hasil terbaik, sampai dengan ditemukan konfigurasi yang paling sesuai.

Penyesuaian *hyperparameter* yang sama dilakukan terhadap setiap *backbone* yang digunakan. Setelah dilakukan percobaan penyesuaian didapatkan penentuan setiap *hyperparameter* dengan hasil model paling baik diantara seluruh percobaan yang dilakukan. Model paling baik dengan menggunakan konfigurasi yang sama, jumlah pekerja atau *number of worker 2*, ukuran *batch 2*, *learning rate 0.0001*, jumlah iterasi 1000 dan ukuran *RoI Heads* sebesar 256.

Berdasarkan *hyperparameter* yang telah ditetapkan, proses pelatihan dilaksanakan dengan menggunakan akselerator perangkat keras *Graphics Processing Unit (GPU) V100* melalui *Google Colaboratory Pro Plus*. Penerapan *GPU V100* mempengaruhi waktu pelatihan model dengan berbagai jenis *backbone*, sebagaimana tercatat dalam Tabel 2. Rata-rata waktu komputasi dari pelatihan yaitu selama sekitar 22 menit. Secara spesifik, model yang mengadopsi *backbone ResNet50-DC5* mencapai waktu pelatihan paling singkat, yakni 20,30 menit, menunjukkan tingkat efisiensi yang lebih bagus dalam pengolahan dan pembelajaran model dengan kombinasi tertentu dari arsitektur *backbone* dan tipe *GPU* ini. Di sisi lain, waktu pelatihan paling lama tercatat pada model dengan *backbone ResNet50-FPN*, mencapai 23,43 menit. Selisih perbedaan waktu pelatihan antara kedua *backbone* tercepat dan terlama hanya sekitar 3,13 menit. Observasi ini menyoroti bahwa adanya perbedaan dalam kecepatan pelatihan antara variasi *backbone* dengan penggunaan *GPU V100*.

Tabel 2. Waktu Pelatihan Setiap *Backbone* Model

<i>backbone</i>	waktu pelatihan (menit)
R50-C4	23,07
R50-DC5	20,30
R50-FPN	23,43
R101-C4	22,46
R101-DC5	22,05
R101-FPN	22,11
X101-FPN	21,55

Dalam konteks Mask R-CNN, *Intersection over Union (IoU)* digunakan sebagai penilaian terhadap ketepatan segmentasi objek, membandingkan area yang dihasilkan oleh algoritma dengan *ground truth* atau area sebenarnya dari objek tersebut. Skala nilai *IoU* berkisar antara 0 dan 1, dimana nilai 1 menggambarkan kesesuaian sempurna antara area yang diprediksi dan area aktual. Proses penilaian model dilakukan pada data uji dengan memasukkan metrik-metrik *COCO* untuk segmentasi *instance*. Dalam kategori *Average Precision (AP)* pada *IoU* maksimum untuk kelas *coral* pada penelitian ini, *ResNeXt101-FPN* mencapai prestasi terbaik dalam masker segmentasi dan kotak deteksi di antara semua rangkaian utama yang digunakan, dengan nilai masker segmentasi sebesar 40,5% dan kotak deteksi sebesar 59,9%. *ResNet101-DC5* menduduki peringkat kedua dengan pencapaian masker segmentasi sebesar 38,3% dan kotak deteksi sebesar 54,1%.

Ketika nilai *IoU* mencapai 50%, *ResNeXt101-FPN* terus menunjukkan dominasinya dengan hasil masker segmentasi dan kotak deteksi terbaik dari semua rangkaian utama, mencapai nilai masker segmentasi 83,6% dan kotak deteksi 85,6%. *ResNet101-DC5* menduduki peringkat kedua, dengan nilai kotak deteksi terbaik sebesar 81,9% dan masker segmentasi terbaik sebesar 79,2%.

Saat *IoU* mencapai 75%, *ResNeXt101-FPN* mempertahankan hasil masker dan kotak terbaik dari seluruh rangkaian utama dengan nilai masker segmentasi sebesar 37,1% dan kotak deteksi sebesar 67,1%. *ResNet101-DC5* berada di peringkat kedua dengan nilai masker segmentasi sebesar 35,2% dan nilai kotak deteksi sebesar 62,2%. Dalam konteks objek besar, *ResNeXt101-FPN* terus menonjol sebagai yang terbaik dalam *Average Recall (AR)*, mencapai nilai masker segmentasi 75,3% dan kotak deteksi 53,6%. *ResNet101-DC5* mengikuti di peringkat kedua, dengan nilai masker segmentasi 67% dan kotak deteksi 48,4%.

Sementara dalam kategori *Average Recall (AR)* *ResNeXt101-FPN* menjadi yang terbesar dengan hasil masker segmentasi dan kotak deteksi terbaik dari semua rangkaian utama, mencapai nilai masker segmentasi 75,3% dan kotak deteksi 53,6%. Pada posisi kedua nilai masker terbaik dimiliki oleh *ResNet101-DC5* sebesar 67% dan untuk nilai kotak deteksi terbaik dimiliki oleh *ResNet50-FPN* sebesar 49,8%.

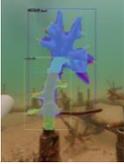
Tabel 3. Hasil Evaluasi *Backbone* Model

<i>backbone</i>	tipe	AP	AP50	AP75	AR100
R50-C4	Mask	35,8	71,2	28,0	64,0
	Box	49,3	72,9	56,5	44,5
R50-DC5	Mask	30,6	64,8	24,8	53,8
	Box	38,3	63,8	35,2	43,0
R50-FPN	Mask	32,9	77,1	24,1	66,2
	Box	45,6	77,9	51,5	49,8
R101-C4	Mask	32,3	75,5	22,5	65,7
	Box	49,9	75,2	53,9	42,8
R101-DC5	Mask	38,3	77,0	35,2	67,0
	Box	54,1	81,9	62,2	48,4
R101-FPN	Mask	38,1	79,2	31,2	65,3

<i>backbone</i>	type	AP	AP50	AP75	AR100
X101-FPN	Box	51,6	79,1	50,2	47,4
	Mask	40,5	83,6	37,1	75,3
	Box	59,9	85,6	67,1	53,6

Selisih antara dua model terbaik pada *Average Precision* (AP) pada IoU Maksimum untuk masker segmentasi antara ResNeXt101-FPN dan ResNet101-DC5 adalah sebesar 2,2%, sementara untuk kotak deteksi adalah sebesar 5,8%. Sementara itu, perbedaan pada *Average Recall* (AR) antara ResNeXt101-FPN dengan ResNet101-DC5 adalah sebesar 8,3% untuk masker segmentasi dan selisih antara ResNeXt101-FPN dengan ResNet101-FPN 3,8% untuk kotak deteksi. Informasi ini akan sangat berguna dalam proses perhitungan laju pertumbuhan karang selanjutnya, memandu pemilihan model yang paling optimal untuk tujuan tersebut. Hasil evaluasi presisi dan *recall* dari setiap *backbone* model dapat dilihat pada Tabel 3.

Tabel 4. Hasil Segmentasi dan Deteksi

<i>backbone</i>	hasil segmentasi dan deteksi
ResNet50-C4	
ResNet50-DC5	
ResNet50-FPN	
ResNet101-C4	
ResNet101-DC5	
ResNet101-FPN	

<i>backbone</i>	hasil segmentasi dan deteksi
ResNeXt101-FPN	

Tabel 4 merupakan beberapa sampel hasil data pengujian dari proses segmentasi dan deteksi objek karang pada citra menggunakan tujuh jenis *backbone*. Proses segmentasi menghasilkan masker yang digunakan dalam perhitungan objek karang pada tahapan berikutnya penelitian ini. Evaluasi kualitas segmentasi dilakukan berdasarkan hasil rata-rata presisi yang diperoleh dari ketujuh jenis *backbone* yang digunakan dalam eksperimen. Secara kasar, dapat diamati bahwa masker ResNeXt101-FPN dan ResNet101-DC5 memberikan visualisasi hasil yang lebih baik dibandingkan dengan *backbone* lain. Meskipun kedua *backbone* ini tampak serupa saat dilihat secara kasar, perbedaan yang signifikan muncul ketika menganalisis nilai rata-rata presisi yang dihasilkan pada Tabel 3. Terutama, ResNeXt101-FPN menonjol sebagai *backbone* terbaik, menghasilkan nilai rata-rata presisi yang lebih tinggi. ResNeXt101-FPN berhasil menutupi hampir seluruh objek karang dalam citra dengan tingkat keberhasilan yang tinggi, terutama pada IoU 50%. Sehingga, berdasarkan hasil eksperimen, X101-FPN menjadi *backbone* yang optimal untuk tugas segmentasi objek karang dalam penelitian ini.

Ukuran rata-rata model dari ketujuh *backbone* dalam satuan Megabyte (MB) adalah 655,49 MB, dengan variasi signifikan antara nilai terkecil 273,72 MB (ResNet50-C4) dan terbesar 1491,33 MB (ResNet101-DC5) sebagaimana yang tercatat dalam Tabel 5. Penyimpangan ini dapat diatribusikan pada perbedaan struktur dan kompleksitas *inherent* dari masing-masing *backbone*. Model yang lebih besar, seperti ResNet101-DC5, cenderung memperlihatkan peningkatan jumlah parameter dan lapisan, yang secara positif berkontribusi pada kapasitas untuk mengelola informasi yang lebih kompleks. Meskipun demikian, kelebihan ini juga menciptakan ukuran model yang lebih besar. Di sisi lain, model yang lebih kecil, seperti ResNet50-C4, membatasi jumlah parameter, yang dapat menghasilkan ukuran model yang lebih kompak, namun memiliki keterbatasan dalam menangani tingkat kompleksitas tertentu.

Tabel 5. Ukuran Model Setiap *Backbone*

<i>backbone</i>	ukuran model (MB)
ResNet50-C4	273,72
ResNet50-DC5	1342,85
ResNet50-FPN	342,79
ResNet101-C4	422,19
ResNet101-DC5	1491,33
ResNet101-FPN	491,27
ResNeXt101-FPN	836,12

Tabel 6 merinci waktu inferensi untuk setiap model *backbone* dengan menggunakan dataset

seragam yang terdiri dari 50 foto karang transplantasi. Pengukuran ini mencakup total waktu komputasi, diukur dalam menit, yang diperlukan oleh masing-masing model selama fase inferensi. Rentang waktu inferensi menunjukkan variasi yang cukup signifikan, mulai dari 8,12 menit hingga 24,40 menit. Analisis lebih mendalam terhadap variabilitas waktu inferensi ini mengindikasikan bahwa struktur dan kompleksitas intrinsik dari masing-masing *backbone* berpengaruh signifikan terhadap efisiensi komputasionalnya. Terutama, ketika diterapkan pada set data yang sama, perbedaan waktu inferensi mencerminkan kapabilitas relatif dari setiap model dalam menangani tugas deteksi dan segmentasi objek pada citra-citra tersebut. Model dengan waktu inferensi yang lebih singkat, seperti ResNet50-FPN, menunjukkan kemampuan untuk melakukan inferensi dengan kecepatan tinggi, sementara model dengan waktu inferensi yang lebih lama, seperti ResNet101-C4, menunjukkan kemampuan untuk melakukan inferensi dengan kecepatan rendah.

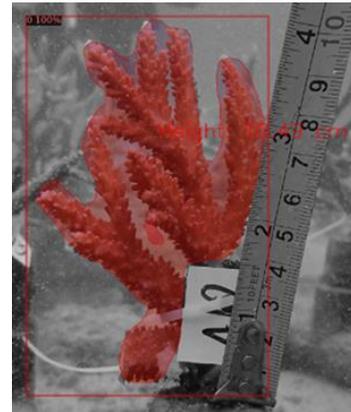
Tabel 6. Waktu Inferensi Setiap *Backbone*

<i>backbone</i>	total waktu komputasi (menit)
ResNet50-C4	17,73
ResNet50-DC5	19,12
ResNet50-FPN	08,12
ResNet101-C4	24,40
ResNet101-DC5	12,80
ResNet101-FPN	09,10
ResNeXt101-FPN	20,12

Berdasarkan analisis dan evaluasi yang dilakukan terhadap setiap *backbone* diujikan, dengan mempertimbangkan presisi, recall, ukuran model, dan waktu inferensi yang dihasilkan, diputuskan untuk menggunakan model dengan *backbone* ResNeXt101-FPN dalam tahap perhitungan karang. Pemilihan ini berdasarkan fakta bahwa ResNeXt101-FPN menunjukkan nilai presisi dan recall yang signifikan secara statistik lebih tinggi daripada *backbone* lainnya yang diuji. Keputusan ini diambil mengingat bahwa tingkat presisi dan *recall* yang dihasilkan oleh setiap *backbone* masih rendah, namun ResNeXt101-FPN menunjukkan peningkatan yang nyata dalam performa, sebagaimana ditunjukkan dalam analisis dan evaluasi yang telah dilakukan pada Tabel 3.

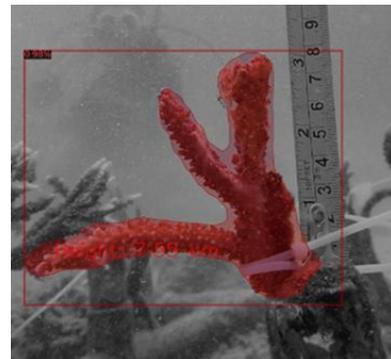
Hasil dari penggunaan *backbone* ResNeXt101-FPN digunakan untuk langkah selanjutnya dalam menghitung laju pertumbuhan terumbu karang. Agar proses yang dilakukan valid, karang yang digunakan untuk objek perhitungan kalibrasi sebagai faktor konversi adalah karang yang sudah diukur dengan pengukur seperti pada Gambar 8 dibawah. Setelah dihitung dengan menggunakan persamaan yang melibatkan perbedaan nilai  $y$  maksimum dan minimum pada masker, diperoleh nilai piksel sebesar 2142 dengan jarak foto 20 cm dari permukaan karang. Selanjutnya, nilai tersebut dibagi dengan jarak tinggi sebenarnya pada karang yaitu sebesar lebih kurang 10,49 cm. Sehingga berdasarkan pembagian tersebut diperoleh faktor konversi untuk kalibrasi tinggi yaitu

sebesar 0.004897601034551586. Selanjutnya, untuk menemukan tinggi dalam satuan sentimeter, nilai tinggi yang diperoleh dalam satuan piksel sebesar 2142, dikalikan dengan faktor konversi tinggi yang diperoleh yaitu sebesar 0.004897601034551586. Hasil perkalian antara tinggi piksel dengan faktor konversi tinggi diperoleh sebesar 10,49 cm. Hal ini menandakan bahwa tinggi dari karang sudah sesuai dengan tinggi sebenarnya seperti pada pengukur sebesar 10,49 cm. Hasil dari visualisasi masker dan kalkulasi jarak tinggi bisa dilihat pada Gambar 8.



Gambar 8. Hasil Pengukuran Tinggi

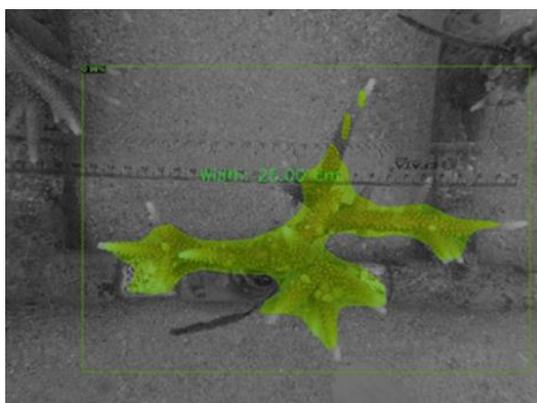
Untuk memastikan keakuratan kalibrasi, juga digunakan citra lain yang telah disandingkan dengan pengukur. Gambar 9 menunjukkan hasil pengukuran yang sama dengan tinggi sebenarnya pada terumbu karang yaitu sebesar 7,55 cm.



Gambar 9. Hasil Pengukuran Tinggi Pendukung

Hasil dari penggunaan *backbone* X101-FPN juga digunakan untuk langkah selanjutnya dalam proses pengukuran pertumbuhan lebar karang. Proses yang dilakukan pada dasarnya sama dengan proses yang dilakukan pada pengukuran pertumbuhan tinggi. Agar proses yang dilakukan valid, karang yang digunakan untuk objek perhitungan kalibrasi sebagai faktor konversi ini adalah karang yang sudah diukur dengan pengukur seperti pada Gambar 10. Setelah dihitung dengan menggunakan persamaan yang melibatkan perbedaan nilai  $x$  maksimum dan minimum pada masker, diperoleh nilai piksel sebesar 5970 dengan jarak foto 20 cm dari permukaan karang. Selanjutnya, nilai ini dibagi dengan jarak lebar

sebenarnya pada karang yaitu sebesar 25 cm. Sehingga berdasarkan pembagian tersebut diperoleh faktor konversi untuk kalibrasi lebar yaitu sebesar 0.004187604690117252. Selanjutnya, untuk menemukan lebar dalam satuan sentimeter, nilai lebar yang diperoleh dalam satuan piksel sebesar 5970, kemudian dikalikan dengan faktor konversi lebar yang diperoleh yaitu sebesar 0.004187604690117252. Hasil perkalian antara lebar piksel dengan faktor konversi lebar diperoleh sebesar 25 cm. Hal ini menandakan bahwa lebar dari karang sudah sesuai dengan lebar sebenarnya seperti pada pengukur sebesar 25 cm. Hasil dari visualisasi masker dan kalkulasi jarak lebar bisa dilihat pada Gambar 10.



Gambar 10. Hasil Pengukuran Lebar

Hasil faktor konversi yang diperoleh dari satu citra dapat digunakan ke seluruh citra lain tanpa harus dikalkulasikan faktor kalibrasi dari citra-citra baru. Hal ini sangat memberikan kemudahan dalam mengkalkulasikan tinggi dan lebar dari setiap karang yang ingin dilihat pertumbuhannya

#### 4. KESIMPULAN DAN SARAN

Model yang dihasilkan dari implementasi Mask R-CNN melalui *backbone* ResNeXt101-FPN mampu secara otomatis melakukan perhitungan terhadap laju pertumbuhan pada citra karang transplantasi melalui segmentasi yang dihasilkan. Evaluasi model menunjukkan bahwa waktu yang dibutuhkan untuk melakukan perhitungan terhadap 50 citra transplantasi karang adalah selama 21,22 menit. Proses perekaman citra juga dapat dilaksanakan dengan cepat, di mana dalam waktu terbatas, penyelam mampu merekam 570 citra bersih dalam. Dengan demikian, para konservasionis cukup merekam citra sebanyak mungkin dan menghitung pertumbuhan karang melalui model di darat. Hasil ini memberikan kontribusi signifikan dalam pengembangan metode pemantauan pertumbuhan karang pasca-transplantasi, serta menunjukkan potensi penerapan teknologi ini dalam upaya konservasi terumbu karang.

Saran untuk penelitian selanjutnya yaitu untuk melakukan penambahan dataset citra karang transplantasi dengan lokasi dan variasi yang lebih

universal agar model dapat mengenali beragam citra karang selain dari lokasi yang dilakukan pada penelitian ini. Melatih model menggunakan algoritma segmentasi alternatif *deep learning* lainnya, sehingga dapat diperoleh pemahaman yang lebih komprehensif terhadap hasil dan mendapatkan akurasi yang lebih baik. Melakukan perhitungan tinggi dan lebar dari segmentasi citra karang dengan metode perhitungan lain yang bisa diterapkan dengan lebih baik.

#### DAFTAR PUSTAKA

- AGNEW, C., EISING, C., DENNY, P., SCANLAN, A., VAN DE VEN, P., & GRUA, E. M., 2023. Quantifying the Effects of Ground Truth Annotation Quality on Object Detection and Instance Segmentation Performance. *IEEE Access*, 11, pp.25174–25188. <https://doi.org/10.1109/ACCESS.2023.3256723>
- AKSHAYANIVASHINI C.V., & KRISVAN P., 2023. Deep Learning-Based Instance Segmentation of Aircraft in Aerial Images using Detectron2. <https://ssrn.com/abstract=4485468>
- ALAMSYAH, R., USPAR, PERMATASARI, A., & NURFADILLAH., 2019. Sebaran dan Luasan Terumbu Karang di Perairan Pulau Larearea Menggunakan Citra Landsat 8. In *Jurnal Agrominansia*, Vol. 4, Issue 1.
- BUDI, R., HARIANTO, A.R., & SETYATI, E., 2023. Segmentasi Citra Area Tumpukan Sampah Dengan Memanfaatkan Mask R-CNN. *Journal of Intelligent System and Computation*, 5(1), pp.58–64. <https://doi.org/10.52985/insyst.v5i1.305>
- BUKHARI, B., PUTRA, R.D., & KURNIAWAN, D., 2021. Optimasi Penggunaan Waktu Pembersihan untuk Sukses Transplantasi Karang Acropora Millepora di Perairan Malang Rapat, Bintan, *Jurnal Kelautan Nasional*, 16(2), pp.145-156.
- DE CARVALHO, O.L.F., DE CARVALHO, O.A., ALBUQUERQUE, A. O. DE, BEM, P. P. DE, SILVA, C. R., FERREIRA, P. H. G., DE MOURA, R. D. S., GOMES, R. A. T., GUIMARÃES, R. F., & BORGES, D. L., 2021. Instance segmentation for large, multi-channel remote sensing imagery using mask-RCNN and a mosaicking approach. *Remote Sensing*, 13(1), pp.1–24. <https://doi.org/10.3390/rs13010039>
- FERSE, S.C.A., HEIN, M.Y., & RÖLFER, L., 2021. A survey of current trends and suggested future directions in coral transplantation for reef restoration. In *PLoS ONE*. Vol. 16, Public Library of Science. <https://doi.org/10.1371/journal.pone.0249966>
- GONZALEZ, S., ARELLANO, C., & TAPIA, J., 2019. DeepBlueBerry: Quantification of Blueberries in the Wild Using Instance Segmentation.

- <https://doi.org/10.1109/ACCESS.2019.2933062>
- SANUSI A.P., FARIZA, A., & SETIAWARDHANA., 2023. Klasifikasi Tinggi Badan Menggunakan Metode Mask R-CNN. *Indonesian Journal of Computer Science Attribution*, 12(4), p.2050.
- LEI, X., PAN, H., & HUANG, X., 2019. A dilated cnn model for image classification. *IEEE Access*, Vol. 7, pp.124087–124095. <https://doi.org/10.1109/ACCESS.2019.2927169>
- MA, X., LI, Z., & ZHANG, L., 2022. An Improved ResNet-50 for Garbage Image Classification. *Tehnicki Vjesnik*, 29(5), pp.1552–1559. <https://doi.org/10.17559/TV-20220420124810>
- PHAM, V., PHAM, C., & DANG, T., 2020. Road Damage Detection and Classification with Detectron2 and Faster R-CNN. *Proceedings - 2020 IEEE International Conference on Big Data, Big Data 2020*, pp.5592–5601. <https://doi.org/10.1109/BigData50022.2020.9378027>
- RIDHOVAN, A., & SUHARSO, A., 2022. Penerapan Metode Residual Network (Resnet) dalam Klasifikasi Penyakit pada Daun Gandum. *Jurnal Ilmiah Penelitian dan Pembelajaran Informatika*. Pp.58-65. <https://doi.org/10.29100/jipi.v7i1.2410>
- RUMKOREM, O. L. Y., KURNIA, R., & YULIANDA, F., 2019. Asosiasi Antara Tutupan Komunitas Karang Dengan Komunitas Ikan Terumbu Karang Di Pesisir Timur Pulau Biak, Kabupaten Biak Numfor. *Jurnal Ilmu Dan Teknologi Kelautan Tropis*, 11(3), pp.615–625. <https://doi.org/10.29244/jitkt.v11i3.23375>
- WONG, A.S., VRONTOS, S., & TAYLOR, M. L., 2022. An assessment of people living by coral reefs over space and time. *Global Change Biology*, 28(23), pp.7139–7153. <https://doi.org/10.1111/gcb.16391>
- SOUTER, D., PLANES, S., WICQUART, J., LOGAN, M., OBURA, D., & STAUB, F., 2020. *Status of Coral Reefs of the World: 2020 Executive Summary*.
- TAHIR, H., IFTIKHAR, A., & MUMRAIZ, M., 2021. Forecasting COVID-19 via registration slips of patients using ResNet-101 and performance analysis and comparison of prediction for COVID-19 using faster R-CNN, mask R-CNN, and ResNet-50. *Proceedings of the 2021 1st International Conference on Advances in Electrical, Computing, Communications and Sustainable Technologies, ICAECT 2021*. <https://doi.org/10.1109/ICAECT49130.2021.9392487>
- VO, A. H., SON, L.H., VO, M.T., & LE, T., 2019. A Novel Framework for Trash Classification Using Deep Transfer Learning. *IEEE Access*, Vol. 7, pp.178631–178639. <https://doi.org/10.1109/ACCESS.2019.2959033>
- ZHOU, T., ZHAO, Y., & WU, J., 2021. ResNeXt and Res2Net Structures for Speaker Verification. *2021 IEEE Spoken Language Technology Workshop, SLT 2021 - Proceedings*, pp.301–307. <https://doi.org/10.1109/SLT48900.2021.9383531>

*Halaman ini sengaja dikosogkan.*