

# ブルーカーボン貯留量の測定のための藻類識別

Creation of algal identification for measurement of blue carbon sequestration

研究学生：木下 涼太

指導教員：江崎 修央

## 1. はじめに

近年、気候変動や黒潮の大蛇行により、太平洋沿岸域の海洋環境は大きく変化している。漁業においては、水温上昇等によって発生する磯焼けの影響で小魚が減少し、それを餌とする魚介類の漁獲量の低下が問題になっている<sup>[1]</sup>。現在の状況を解決し、持続可能な漁業を目指すためには、海洋環境の計測と経年的な藻場の分布状況、海藻種類構成等を把握する必要がある。

また、近年では脱炭素社会へ向けた取り組みが加速しており、ブルーカーボン生態系の炭素貯留機能が注目されている<sup>[2]</sup>。特に、海藻類は陸域の植物に比べ炭素貯留量が多く、長期間にわたり炭素を隔離・貯留することができる。そのため、さまざま企業や自治体でブルーカーボンを活用する取り組みが行われているが、海藻の現存量を定量化する方法については検討の余地があり、炭素貯留量の測定方法を確立していく必要がある。

本研究では、海域を操業する漁船にカメラを用いた映像収集装置を設置することで、海藻藻場を把握するシステムの構築を目指す。

## 2. システム概要

藻場の炭素貯留量評価システムの概要を図1に示す。本システムでは、水中ドローンや漁船に取り付け可能な映像収集装置を用いた映像データの収集を行う。収集された映像データに対しては、Semantic Segmentation<sup>[3]</sup>という深層学習に基づく技術を用いて藻の種類を精密に識別し、画像中の海藻領域を抽出する。続いて、写真測量ソフトウェア Pix4Dmapper を活用して、これらの映像から 3D 点群データを生成し、水中の地形や藻場の立体構造をモデル化する。この 3D モデルに Semantic Segmentation で識別された藻類の情報を組み合わせることで、注目海域の各種藻類の体積を正確に算出し、藻類ごとの炭素貯留係数を掛け合わせることで炭素貯留量の評価を行う。

最終的に、このシステムを用いることで、海洋環境の変化に応じた持続可能な漁業の支援と脱炭素社会への貢献を目指す。また、従来の高コストな調査方法に代わる、経済的で実施頻度の高い調査の実現を目指す。

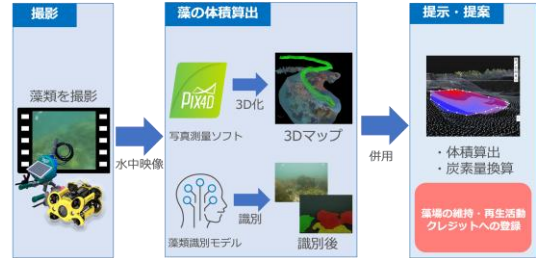


図1 炭素貯留量の評価方法の概要

## 3. 水中ドローンによるデータ収集

2023 年に水中ドローンで撮影した藻場の地域を表1に示す。漁業関係者の協力のもと、水中ドローンや船に取り付けた映像収集装置で撮影を行った。今年度は6箇所、8回のデータ収集を行い、収集した水中映像から、藻類の識別モデルの構築および検証を進めている。

表1 水中ドローンの撮影日と撮影地域

撮影日	撮影した地域
2023/04/14	石鏡
2023/04/19	坂手島
2023/04/21	石鏡
2023/05/10	浦村
2023/06/19	石鏡
2023/07/26	大築海島・菅島
2023/11/22	相差
2023/12/18	大築海島・菅島

## 4. Semantic Segmentation を用いた藻類識別

藻類識別には、深層学習を活用した Semantic Segmentation を採用した。この手法は、画像データ内の画素単位でラベル付けを行うことができるため、異なる藻類を正確に識別することが可能である。Semantic Segmentation は、画像内の物体の境界を精密に捉える能力に優れているため、物体の存在を検出するだけでなく、その形状や範囲を正確に特定できる。このピクセルレベルでの識別性能は、海藻の体積を算出する上で重要である。

## 5. 藻類識別モデルの作成

図2に藻類識別モデルの概要図を示す。本研究では、高性能な DeepLab v3+<sup>[4]</sup>をベースにして、Semantic Segmentation モデルを構築した。ネットワークのバックボーンとして Xception を採用した。Pascal VOC2012 データセット (20クラス, 11530 枚)

で事前に学習されたモデルを利用し、転移学習を行った。アラメ・カジメ、ガラモ、紅藻の3種類を対象とし、異なる海藻種を正確に識別するため、200枚の高解像度画像(3840×2160ピクセル)を学習データとして使用し、各海藻種に対応するアノテーションタグを付与した(図3)。モデルの学習では、150,000回の繰り返しを行い、バッチサイズを2に設定した。この設定はモデルの学習効率とメモリ利用のバランスを考慮して選択した。また、学習画像のクロープサイズは513に設定した。画像の重要な特徴を保持しつつ、モデルの計算負荷を最適化した。

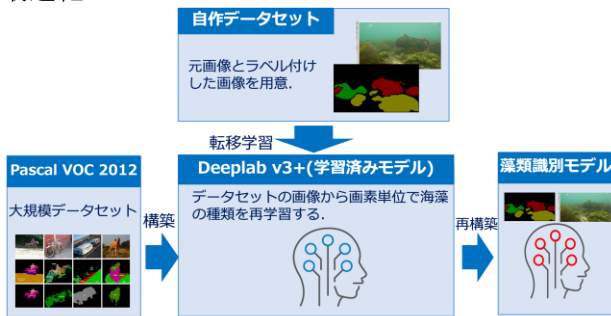


図2 藻類識別モデルの概要




図3 ラベル付けした画像とラベルマップ画像

張技術の適用や、紅藻に関する追加の学習データを収集し、モデルが紅藻の特徴をより詳細に学習できるように改善する必要があると考えている。





図4 IoUの計算式

表2 各クラス9枚ずつ用意し算出したIoUの結果

	アラメカジメ	ガラモ	紅藻
1	0.6470	0.7337	0.3207
2	0.7104	0.3935	0.1441
3	0.3974	0.2157	0.4440
4	0.6512	0.6148	0.2982
5	0.5626	0.4988	0.3278
6	0.4236	0.5262	0.4437
7	0.5737	0.1889	0.3648
8	0.6065	0.3785	0.3553
9	0.4664	0.2337	0.4009



(a) 実際の領域画像 (b) 予測した領域画像

図5 藻類識別モデルによる推論結果

## 6. 藻類識別モデルの精度評価

藻類識別モデルの精度評価には、IoU (Intersection over Union) を用いて行った。IoUとは、予測された領域と実際の領域の積を、予測された領域と実際の領域の和で除したものである。表2に各クラス9枚に対するIoUの結果を示す。

評価結果から、アラメ・カジメのIoUは0.3974から0.7104の範囲に分布し、比較的高い識別性能を示している。ガラモは0.1889から0.7337の範囲であり、若干低い識別結果となった。また、紅藻に関しては、全体的に低い識別精度を示している。

特に紅藻のIoUが最も低い値(0.1441)を示したことに注目し、実際の領域の画像(図5a)において紅藻の占める領域が、他のクラスに比べて少ないことが原因であると考えられる。つまり、紅藻領域の多い画像を選択することで、識別率の向上が期待できると考える。

これらの結果から、藻類識別モデルはアラメ・カジメやガラモの識別においては、比較的優れた性能を発揮するが、紅藻の識別においては、改善の余地があるという結論に至った。そのため、画像内で紅藻が占める領域を増やすためのデータ拡

## 8. まとめと今後の予定

本研究では、水中カメラを用いた映像収集装置を作成し、藻類識別モデルと組み合わせることで、局所的な海域の藻類識別を可能にした。

今後は観測画像を増やすことで識別する藻類を増やし、モデルの精度を向上させる。また、Pix4Dmapperを用いて作成した3Dマップと識別モデルを併用することで種類ごとの体積換算を可能にし、種別で海藻を定量化する予定である。

## 参考文献

- [1] 尾鷲市水産農林課「尾鷲の漁業R1年度版」  
<https://www.city.owase.lg.jp/cmsfiles/contents/0000011/11344/r01owasepart1.pdf> (2024年1月22日参照)
- [2] ブルーカーボンとは—注目される背景、政府・企業の取り組み  
<https://ggpartners.jp/article/000227.html> (2024年1月22日参照)
- [3] セマンティックセグメンテーションとは  
<https://aiacademy.jp/media/?p=3259> (2024年1月22日参照)
- [4] DeepLab v3+ (意訳)  
<https://qiita.com/mine820/items/14e7c556b358dbc4ee9a> (2024年1月22日参照)