

# ROVと物体検出AIモデルYOLOを用いた 藻場の連続被度算定手法

国立研究開発法人土木研究所 寒地土木研究所 水産土木チーム ○菅原 吉浩

潜水士が不足する中、高度で効率的な藻場モニタリング手法の構築を目的とした、ROVの動画と物体検出AIを組み合わせた藻場面積の割合（被度）の自動算定手法を検討した。この結果、限られたAI学習データを増幅することで、AIによる藻場検出精度が大幅に向上するとともに、従来の潜水士では点在した被度情報の取得のみに限られていたが、AIにより測線全体の連続した被度分布を評価できることを明らかにした。

キーワード：AI、深層学習、画像解析、ROV、ブルーカーボン

## 1. はじめに

コンブやアマモに代表される藻場は、沿岸生態系における生物多様性の基盤であり、多くの水産有用種の産卵・育成場として漁業を支えている。近年では、光合成を通じて二酸化炭素を吸収・貯留するブルーカーボン生態系としての役割が注目され、その保全・再生は気候変動対策の観点からも喫緊の課題となっている<sup>1)</sup>。しかし、世界的な海水温の上昇や局所的な海洋環境の変化により、藻場の衰退や消失などの、いわゆる「磯焼け」が各地で深刻化しており、その実態を正確かつ継続的に把握するためのモニタリング技術の確立が急務である。

従来、藻場調査は潜水士による直接観察が主として行われてきた。この手法は、海藻の種類や被度を潜水士が直接目視で評価するため、質の高いデータが得られる一方、潜水士の高齢化と担い手不足が深刻化していることや、予算上の制約からモニタリング調査の実施が難しい場合もある。また、積雪寒冷地である北海道では年中、海水が低温環境下であり、身体的・時間的制約が厳しい条件下で潜水作業を強いられる。さらに、1日当たりの作業量には限界があり、調査範囲はあらかじめ設定した代表測線に限定されるため、広域の藻場分布を面的に評価することは困難であった。

この課題に対し、衛星や航空機、UAV（ドローン）を用いたリモートセンシング技術が近年導入されてきたが、水の濁りや水深に影響されやすく、詳細な生物種構成や群落構造の把握には限界がある。特に、高密度な群落では、レーザー光や音響が上層の葉状体に遮蔽され、下層の状況を正確に捉えられないという問題も指摘され

ている<sup>2)</sup>。

そこで本研究では、潜水士調査の「質の高さ」とリモートセンシングの「効率性」を両立するアプローチとして、遠隔操作無人探査機（ROV）による水中動画と、深層学習を用いたAI画像解析技術の融合に着目した。ROVは、潜水士に代わって安全かつ効率的に水中映像を取得できるため、この膨大な映像データをAIで自動解析することにより、連続的かつ定量的なモニタリングの実現が期待される。

近年、AI、特に深層学習モデルを用いて水中映像から海藻を検出し、被度を算出する研究が報告されているが、国内における研究事例はまだ十分とは言えない。また、これまでに報告されている研究では、特定の海域や撮影条件に最適化された「特化型モデル」が用いられており、光環境や海藻の種類・生育状況が異なる他の場所や時期に適用した場合、精度が著しく低下するという「汎用性」の課題が指摘されている。また、高精度なAIモデルの構築には、専門家による大量のアノテーション（教師データの作成）作業が必要であり、その人的・時間的コストは実用化への大きな障壁となっている<sup>3)</sup>。

本研究では、アノテーションコストと精度のバランスを考慮し、物体検出モデル「YOLO」を用いて、ROVで撮影した動画からコンブ、紅藻、その他雑海藻、海藻以外のクラス別の被度を自動的に算出する手法を開発し、その有効性を検証する。また、限られたアノテーションデータから物体検出精度を向上させるためのデータ増幅の有効性についても定量的に検討する。本研究を通じて、潜水作業を補完・代替し、より広範囲を定量的に評価可能な藻場モニタリング手法の確立を目指すものである。

## 2. 調査方法

### (1) 藻場調査




図-1 調査位置 (元稲府漁港)




図-2 水中カメラの設置 (左: ROV、右: 調査船)

現地調査は北海道のオホーツク海に面する元稲府漁港で実施した。本漁港は図-1に示すように、静穏度対策のため混成堤と消波ブロック式傾斜堤の2重堤構造とされており、2重堤間は投石により水深1.5m程度の浅場が造成され、リシリコンブを主体とした藻場となっている。

本研究で解析対象とする海底藻場の動画は、2023年7月に、図-1に示す赤色の測線上L=50mを対象に、水中カメラ(Gopro)を海底面へ向けて搭載したROVおよび調査船(図-2)を航行させ、後述する機械学習のデータとした。また、測線上の被度の実態を把握するとともに、ROVの航行座標を把握するため、L=50m区間内に10m間隔5箇所0.5m四方の方形枠が付いたロープを展開した。測線両端の座標は船上のGPSで計測した。ROV自体にはGPSが搭載されていないため、ROV本体の映像を船上のモニターで確認しながら、ロープ上に沿った調査を行った。一方、調査船については、測線両端に設置したボンデンを目印にするとともに、船上のPCにて船の位置をGPSで確認しながら、測線上へ誘導を行った。なお、潮位変化の影響を避けるため、潮止まりの時間帯に実施し、調査期間中の潮位は0.17~0.23mと概ね一定であった。

カメラと海底との距離は、調査手法によって異なり、調査船では水面下約1.0mの位置に水中カメラを固定しており、測線上の現地盤水深は1.5~2.0m程度であることから、海底からのカメラ高度は0.7~1.2mとなった。一方、ROVの航行深度は、動画内に映る方形枠の大きさとGoproの視野角(縦90°、横120°)から海底上約0.4mと推定された。これらの条件から、動画1フレームあたりの撮影範囲は、調査船では縦1.5m×横2.5m、ROVが縦

1.0m×横2.0mと推定され、通常の方角枠(1.0m四方)より広範囲の被度を把握していることとなる。

動画の撮影本数は、調査船およびROVともに各2回、同一測線上を航行し、計4本の動画を取得した。

### (2) AI解析方法

本研究で用いるAI解析は、主に教師データセットの作成、AIモデルの学習、精度の検証という3つの工程にて実施した。

まず、教師データセットの作成工程では、深層学習モデルに不可欠なアノテーションデータを準備した。アノテーションとは、画像内の対象物に対して、その位置と種別(クラス)の正解情報を手動で付与する作業である。本研究では、ウェブベースのプラットフォームであるRoboflowを使用した。アノテーションの手法には、各クラスの周囲の輪郭を詳細になぞるセマンティックセグメンテーションや、矩形の領域で設定するバウンディングボックス等があるが、海藻の複雑な形状をピクセル単位でなぞるセマンティックセグメンテーションは膨大な労力を要する。そのため、本研究では実務的な作業を想定し、バウンディングボックスを採用した。アノテーションデータは、(1)で取得した4本の動画から各250枚ずつ、合計1,000枚の静止画を抽出して作成した。

次に、AIモデルの学習工程では、物体検出モデルとしてリアルタイム性と精度のバランスに優れたYOLO(You Only Look Once)を採用した。YOLOは、Ultralytics社が提供する畳み込みニューラルネットワークを用いた機械学習モデルである。本研究では、今後のセマンティックセグメンテーションによる比較検討も視野に入れ、これに対応しているYOLOv8を用いた。また、使用するPCの性能等に応じて選択可能な5段階のモデルサイズの中から、本研究では中間的なMediumモデル(YOLOv8m)を選択した。本研究の計算処理には、NVIDIA社製のGeForce RTX 4070 Ti SUPER GPUを用いたが、Mediumモデルによる1ケース当たりの処理時間は最大で約40時間を要した。

さらに、限られたデータからモデルの学習精度を高めるとともに、データ増幅の有効性を検証するため、①増幅なし(学習データ増幅を行わない場合、データ数0.1万枚)、②増幅1(回転、反転によりデータを0.7万枚まで増幅)、③増幅2(回転、反転、色調調整によりデータを1.5万枚まで増幅)の3ケースで比較を行った。なお、データ増幅はRoboflow上でも可能であるが、本研究ではpython上でデータを拡張した。

この拡張後のデータセットの内、70%をYOLOの訓練データ、30%を学習精度検証用のデータとして分割した。アノテーションの分類クラスはコンブ、紅藻、その他雑海藻、および岩盤の4クラスとした。当該区域のコンブは主にリシリコンブであり、スジメも一部含まれるが、アノテーション上は同一とした。紅藻については主にアカバ、ダルス、クロハギンナンソウが、その他の雑海藻

はウガノモク、無節サンゴモ、カレキグサ（本来紅藻であるが便宜上雑海藻に含める）が見られたが、4分類以外の海藻種別毎の細かい分類は行わなかった。



図-3 アノテーションの一例

図-3にアノテーションの一例を示す。図中の枠が各分類クラスであり、コンブ（茶）、紅藻（赤）、その他の雑海藻（緑）、現地盤（青）としている。海藻は複雑な形状であるため、1つのボックスだけでは囲いきれないことが多く、その場合には複数のボックスで分割して対象を囲んだ。また、過度にボックスが小さくなることを避け（究極的には1ピクセル毎の設定となるが現実的でないため）、ある程度大きなボックス（ボックス内の主要なクラスが概ね80%以上となるよう）を描き、その内部に別のクラスが存在する場合には、その部分をさらに別なボックスで重ねて囲う手法（その場合も当該クラスが概ね80%以上となるよう範囲指定）を採用した。なお、本研究のアノテーションは全て著者1名のみで実施したため、作業者間の判断基準の差異による誤差は含まれないと考えられる。アノテーション作業時間は1日8時間当たり100枚程度で、0.1万枚に対して10日程度を要した。

### 3. 結果と考察

#### (1) 藻場調査結果




図-4 海藻被度と組成の経年変化

図-4に海藻被度（赤丸）と被度組成（積上棒グラフ、重量）の経年変化を示す。2023年7月以前の過去の調査結果も参考までに記載している。各年の海藻種は褐藻であるリシリコンブが卓越しており、コンブ以外には、その他褐藻（スジメ、ウガノモク等）、紅藻（無節サンゴ

モ類、イソキリ、アカバ等）、緑藻（アナアオサ等）が見られた。2023年時点では気候変動による海藻種の変化は確認されていないが、2017年6月時点と比べると平均海藻被度は減少傾向にある。各年の海藻被度については、丸山ら<sup>4)</sup>を参考に、Rank1：被度0-4%（大部分は海や岩礁）、Rank2：被度5-49%（海や岩礁、海藻が混在）、Rank3：被度50-100%（大半が海藻）とすると、2018年6月では、全76地点の内、Rank1が16地点、Rank2が28地点、Rank3が32地点で平均被度は47%（内、リシリコンブは40%）であった。2018年9月は全76地点の内、Rank1が26地点、Rank2が33地点、Rank3が17地点で平均被度は28%（内、リシリコンブは24%）であった。2023年7月は全8地点の内、Rank1が0地点、Rank2が4地点、Rank3が4地点で平均被度は50%（内、リシリコンブは45%）であった。




図-5 海藻被度とリシリコンブ湿重量

図-5に2018年6月、9月、2023年7月における方形枠調査によるリシリコンブの被度と湿重量の関係を示す。被度と湿重量は概ね線形関係にあり、決定係数も0.8495と高い相関を示す。なお、2023年7月にはリシリコンブの全長も計測しているが、海藻の長さは被度に関わらず0.1～2.4mの範囲であった。

#### (2) AI学習精度およびデータ増幅の有効性




図-6 F値の変化（データ増幅なし、データ数0.1万枚）




図-7 F値の変化（増幅1、データ数0.7万枚）




図-8 F値の変化（増幅2、データ数1.5万枚）

図-6、図-7、図-8にデータ増幅なしと増幅1、増幅2の学習精度の比較を示す。横軸は信頼度を示しており、モデルが物体を検出した際に、その予測がどれだけ確からしいかを示す0から1のスコアである（1が最も信頼度が高い）。この信頼度に関値を設け、スコアが関値を上回った予測のみを「正解」として採用する。関値を低く設定すれば多くの物体を検出できるが誤検出も増え、高く設定すれば確実な物体のみ検出されるが検出漏れが増えるトレードオフの関係にある。縦軸は精度（Precision）と再現率（Recall）の調和平均であるF値（F-measure）としている。F値の定義を以下、式(1)-(3)に示す。

$$Precision = TP / (TP + FP) \quad (1)$$

$$Recall = TP / (TP + FN) \quad (2)$$

$$F - measure = \frac{2Precision \cdot Recall}{Precision + Recall} \quad (3)$$

ここで、 $TP$ (True Positive)：正解クラスを真と判定した数、 $FP$ (False Positive)：正解クラス以外を真と判定した数、 $FN$ (False Negative)：正解クラスを偽（別なクラス）と判定した数である。なお、F値は0から1.0を示し、

1.0が最も精度が良いことを示す。

データ増幅なしのケース（図-6）において、全クラスの平均F値は信頼度0.2の時に0.4程度のピーク値を示している。しかし、信頼度の閾値がわずかに上がるだけでF値が急激に減少することから、このモデルは特定の閾値でしか最適な性能を発揮できず、信頼性に欠ける不安定なモデルであるということが言える。一方、データ増幅1（図-7）、増幅2（図-8）では、両者とも信頼度の閾値が0.90程度という高いピーク値を示し、信頼度が0.1から0.7までF値が高い水準で横ばいとなっており、信頼性を確保したまま高い精度で検出可能なことから、より実用的で安定したモデルが構築できたことを示している。また、増幅2では増幅1に比べて信頼性0.8付近において紅藻以外のクラスのF値も高い水準で横ばいを保っていることから、データ増幅の際に色調調整を加えることで精度がさらに向上したと考えられる。

表-1 増幅2の混同行列

	コンブ	雑海藻	紅藻	現地盤	誤検出
コンブ	5002	0	1	2	412
雑海藻	0	1600	1	2	129
紅藻	0	0	602	0	54
現地盤	0	0	0	8699	837
未検出	110	54	10	254	0
	コンブ	雑海藻	紅藻	現地盤	誤検出
	正解ラベル (True)				

表-2 各ケースの分類精度（F値）

ケース名	増幅なし	増幅1	増幅2
データ数	0.1万枚	0.7万枚	1.5万枚
コンブ	0.29	0.91	0.95
雑海藻	0.52	0.91	0.95
紅藻	0.52	0.93	0.95
地盤	0.46	0.90	0.94
全体精度(平均)	0.45	0.91	0.95
全体精度(重み)	0.21	0.86	0.92

表-1に、増幅2の混同行列を示す。混同行列とはモデルのクラスごとの分類性能を詳細に評価するものであり、縦軸がモデルの予測クラス、横軸が正解クラスで、数値は検出データ数を示している。つまり、縦軸（列）の合計が各クラスの全正解データ数、横軸（行）の合計が各クラスのAIの全予測データ数を示す。たとえば、現地盤の場合は8,957個の正解値に対して、実際に現地盤と分類されたのが8,699個、雑海藻と誤分類されたのが2個、未検出（4クラスのいずれにも分類されなかったデータ）が254個となる。また、誤検出とは正解ボックスの範囲外を誤って4クラスのいずれかに検出したデータであり、コンブの場合は412個が誤検出されている。混同行列は



対角の数字が多い程、精度が良いことを示す。4クラスの各クラスのデータ数が違うのはアノテーションのデータ数の違いである。未検出や誤検出が見られるものの、対角の数字が大部分を占めており、各クラスで概ね正解クラスに分類されている。

表-2に、データ増幅の有無によるF値の比較を示す。F値の全体精度（平均）は4クラスの単純平均、全体精度（重み）は未検出データのF値を0とした上で各クラスのデータ数の重みを考慮している。増幅なしのF値は0.21と低い値に留まる。これに対し、増幅1では0.86まで向上し、さらに色調調整を加えた増幅2では0.92まで大幅に向上した。

以上の結果から、限られた教師データからでも、データ増幅を適切に行うことで、多様な撮影状況に対応可能な信頼性の高いモデルを構築できることを示しており、AIモデル開発におけるデータ増幅の重要性を裏付けるものである。

### (3) AIによる海藻の自動検出結果



図-9 YOLOによる物体検出の一例

図-9は、本研究で最終的に採用したモデル（データ増幅2）における画像の検出の一例である。枠の色は、茶色：コンブ、緑色：雑海藻、赤色：紅藻、青色：現地盤を示している。コンブだけでなくコンブ以外の紅藻や雑海藻だけでなく、海藻以外の現地盤も検出している。これにより、現地盤の部分を被度から除外することが可能となる。なお、画像にはロープと方形枠も写っているが、方形枠内には紅藻が無いことから、従来の方形枠内の限られた範囲の調査では海藻の構成種を誤って評価する可能性があるため、水中カメラにより方形枠よりも広い範囲を撮影することや、AIで連続して解析することで、様々な海藻を的確に捉えることが可能となる。

次に、AIモデルが教師データをどの程度正確に学習・再現できているかを評価するため、図-10および図-11に、AIによる予測被度（予測値）と、アノテーション作業時に目視で評価した被度（正解値）との相関関係を示す。縦軸（予測値）、横軸（正解値）ともに被度の割合を示し、被度100%を1としている。

図-10（case1）は、動画1コマ当たりの画面全体の大きさを1（被度100%）とみなして、それに対するラベル

毎のボックス面積の合計の割合を被度とする場合である。この方法では、同じ海藻や地盤に対して複数のボックスが重複して検出される場合、累計被度が100%を超えることがある。図-11（case2）は、検出された全ボックスの面積の合計を被度100%とみなして、それに対するラベル毎のボックス面積の合計の割合を被度とする場合で、累計被度は100%となる。

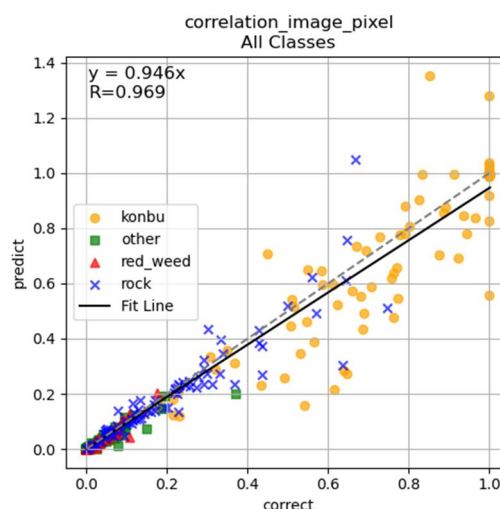


図-10 YOLOによる被度の相関  
(case1 画面の大きさを被度 100%)

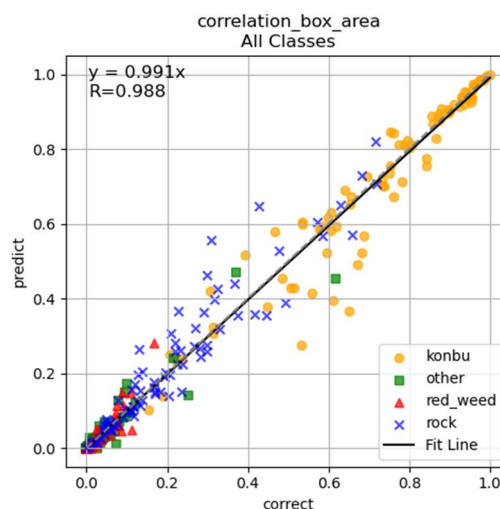


図-11 YOLOによる被度の相関  
(case2 ボックス累計を被度 100%)

図-10（case1）ではボックスの重複により縦軸（予測値）が最大で1.4（被度140%）に達している。一方、図-11（case2）では近似直線はほぼ $y=x$ となり、決定係数も $R^2=0.988$ とcase1（ $R^2=0.969$ ）より高い相関を示した。また、case1ではバウンディングボックスの重複によって被度が過大評価されているが、case2の手法ではボックスの累計を100%とすることでこの問題が解消される。このことから、YOLOにより海藻種別毎の被度を算定する場合にはcase2の手法がより実態に近い被度を表現で

きると考えられる。

このように、学習させたAIモデルが、目視による被度の判断基準を非常に高い精度で再現できていることが確認された。

#### (4) AIによる海藻被度の時系列

開発したAIモデルの実用性を評価するため、ROVで撮影した動画全体にモデルを適用し、時系列で連続的に算出した被度と、目視による被度を比較した。AIによる被度算出は、前節のCase2（全検出ボックス面積の合計を100%とする手法）を用いた（図-12）。




図-12 YOLO による被度の時系列 (ROV の場合)

AIによる予測被度（折れ線）は、50mの測線区間で地点によって大きく変動しているが、特に、主要な海藻であるコンブの予測被度は、目視による被度（マーカー）の変動傾向と良好に一致しており、本手法が測線上の被度分布を自動で評価できることを示している。

また、AIによる連続データを見ると、被度はわずか1～2mの距離が違っただけで、100%近傍から20%へと急激に変動するパッチ状の藻場分布となっていることが確認できる。これは、従来の方形枠調査のような点在了離散的数据だけでは、測線全体の平均被度や群落構造を代表しているとは限らず、サンプリング地点のわずかなズレが藻場全体の評価に大きく影響しうることを示唆している。

一方で、AIによる予測と正解に乖離が見られる地点も存在した。特に、紅藻やその他雑海藻については、被度が低いエリアでの検出漏れや、コンブとの誤認識により、目視との一致度はコンブほど高くない傾向が見られた。これは、その他雑海藻としていくつかの海藻を一纏めにしたことや、アノテーションデータにおけるサンプル数の不均衡などが影響していると考えられる。

以上の結果から、本研究で開発したAI解析手法は、潜水調査の離散的な情報を、定量的な連続情報へと拡張する上で極めて有効であることが示された。これにより、潜水調査による藻場の空間的な不均一性を軽減し、調査精度と被度算定効率を大幅に向上させることが可能となる。

#### 4. まとめ

本報告では、潜水作業の省力化と高度で効率的な藻場モニタリング手法の構築を目指し、ROVにより撮影した水中動画と物体検出AI「YOLO」を組み合わせた海藻被度の自動算出手法を開発した。その結果、1000枚程度の限られた教師データでも、回転や色調調整といったデータ増幅を行うことで、モデルの信頼性が大幅に向上し、F値0.92という高い検出精度となることを確認した。

また、本手法により、測線上の被度分布を自動で連続的に評価できることを確認した。特に、検出された全ボックスの面積合計を100%として各クラスの被度を算出する方法（Case2）は、決定係数 $R^2=0.988$ と極めて高い精度で教師データを再現でき、実用的な被度推定手法として有効であることが示された。

仮に人力で動画全体の被度を算定する場合、動画の解像度が30fps（1秒間に30コマの画像）とすると、約1分の動画は1,800枚の画像の集合体となるが、著者がアノテーションした実績から1日あたり100枚の早さで被度や海藻種別の整理を行ったとしても、18日という長期間を要することとなり、広範囲を長時間調査した動画を全て人力で解析することは現実的には困難と思われる。

一方、AIモデルを作成するためには、アノテーションやpythonでの解析作業などが別途必要となるが、一度作成した学習モデルを、別な動画（調査測線等）に適用することで作業効率の大幅な向上と広範囲の藻場分布の詳細な把握が可能となる。

このことから、本研究の成果は、効率的かつ高精度な藻場モニタリング技術の確立に寄与するものと言える。

今後は学習済みモデルを別な調査時期へ適用可能か、汎用性の観点で検討することや、データ増幅のさらなる効率的な手法についても検討していきたい。

#### 参考文献

- 1) Kuwae, T. and Hori, M. (Eds.): Blue Carbon in Shallow Coastal Ecosystems: Carbon Dynamics, Policy, and Implementation, Springer, 2019.
- 2) 岩部然育, 土井口華絵, 加藤英紀, 片山美可, 高橋大二朗, 渡辺謙太, 伴野雅之, 石野芳夫: グリーンレーザ測量を用いた藻場把握方法の検討, 土木学会論文集 B3 (海洋開発), Vol.80, 2024.
- 3) Beijbom, O., Edmunds, P. J., Kline, D. L., Mitchell, B. G., Kriegman, D., and others: Towards automated annotation of benthic survey images: Variability of human experts and operational modes of an automated annotator, Proc. of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), pp. 1-8, 2015.
- 4) 丸山修治, 梶原瑠美子, 石井馨: 空撮写真を用いた簡易的な面的海藻被度の把握, 土木学会論文集 B3 (海洋開発), Vol.76(2), pp.828-831, 2020.