

IV-6. ICT 技術等を活用したサンゴの 被度計測技術の開発

目 次

IV-6 ICT 技術等を活用したサンゴの被度計測技術の開発

1. はじめに	IV-6-1-1
2. 技術開発手法	IV-6-2-1
2.1 検証項目	IV-6-2-1
2.2 調査位置	IV-6-2-2
2.3 調査解析、検討の流れ	IV-6-2-3
2.4 調査解析、検討内容	IV-6-2-4
2.5 実施工程	IV-6-2-6
3. 調査・解析結果	IV-6-3-1
3.1 計測効率化の検証	IV-6-3-1
3.2 ドローン撮影画像によるサンゴ被度計測結果	IV-6-3-2
3.3 ドローン撮影画像によるサンゴ被度分類結果	IV-6-3-5
3.4 船舶水中カメラ撮影によるサンゴ礁観測結果	IV-6-3-7
3.5 船舶水中カメラ撮影によるサンゴ被度分類結果	IV-6-3-10
4. 結果のまとめと今後の課題	IV-6-4-1
5. 次年度の計画	IV-6-5-1

IV-6 ICT 技術等を活用したサンゴの被度計測技術の開発

1 はじめに

(1) サンゴ被度計測技術

従来のダイバーによる潜水調査は、サンゴの種類と被度を正確に捉えることは可能である一方、広い範囲を面的に把握するには多大な労力を要する。さらに、遠隔離島のように現地調査頻度や調査日数に制約がある地域においては、短期間に現地を把握できる手法を検討することが重要となる。

これまでのサンゴ被度計測技術は、これまで衛星画像や水中ビデオ画像による解析手法の検討が行われており、衛星画像による被度計測では、100ha 以上の広範囲の概略的なサンゴ被度の分類を、例えば 100ha 規模ではダイバーによる検証データ取得調査から整理解析で約 14 日間で精度 80%で把握できること、また、ダイバーによる水中ビデオ画像による計測は、100～1,000 m²でサンゴの有無の分類を 4～14 日間程度で精度 80%で把握できることが分かっている。(水産庁漁港漁場整備部, 2018)

今年度は、ドローン及び船上水中カメラ撮影(図-VI.6.1.1 参照)により画像計測を行い、群体レベルでのサンゴの分布をもとにサンゴ被度を計測する技術の開発を行った。




図-VI. 6. 1. 1 ICT 技術による小、中、大スケールのサンゴ被度計測イメージ

(2) サンゴ分類手法の高度化の目的

ICT 技術を活用したサンゴ被度分類技術は、これまで「水中ビデオ画像」などによる解析手法の検討が行われた。

サンゴの分類解析では、潜水士のサンゴ分布の目視観察結果を真値として、画像のデータに人間が、サンゴやその他の基質の類似した色調、テクスチャー（柄）、規模などを区分して、類似した画像で自動分類する手法で、サンゴの有無 80%以上の精度で分類できることが実証された。（水産庁漁港漁場整備部，2018）

これらの手法では、分類精度は一定レベルであるものの、分類解析のときに教師データ付与や、画質特性ごとのデータ付与の調整など、人間が介在する必要があることから、膨大な画像データを処理するのに時間を要するという課題があった。

そこで、本技術開発では次年度以降、AI（深層学習モデル）を活用し、実証試験期間内にはサンゴ分類解析にかかる労力の 50%以上の効率化を図り、分類精度 80%以上とすることを目指した。

【本技術開発における AI-人工知能-の定義】


一般に AI：人工知能の定義は「学習・推論・認識・判断などの人間の知能を持たせたコンピュータシステム」とされており、広い意味で単純に解析ソフトを用いて統計解析することも AI を用いた分類手法ともいえなくないが、本技術開発では、大量のデータを、データ入力時以外は解析時に人間が介在せずに、深層学習（ニューラルネットワークの考え方を応用した手法）して分類する手法を「AI（深層学習）を用いた分類手法」と定義した。

※AI：人工知能の言葉が広義であり、技術・研究者と一般市民の考え方の違いにより捉え方が異なるため、本件技術開発内容を明らかにするため「深層学習によるサンゴ被度分類解析（の効率化）」とすることと定義する。

次ページに、既往の教師付き分類手法と、AI（深層学習）による分類手法の違いを通した、AI（深層学習）の可能性について示す。

これまでのサンゴ被度分類の統計的手法（教師付き）分類と、AI（深層学習）による画像分類解析手法の違いを表-VI.6.1.1 に示す。

表-VI. 6. 1. 1 サンゴ被度分類手法の違い

	既往の統計的手法（教師付き分類）	AI（深層学習）による分類手法
分類手法 (効率化)	- 画像のデータを類似した特徴の集団ごとに分類するクラスタリングによって、分類されたクラスごとに人が教師データ（サンゴ、基質や底質、その他の生物）を与えて、解析する手法 - 調査1回ごとの画像に対してクラスタリングと教師付きデータの付与が必要なため、複数回のある場合は、その度ごとにクラスタリングと教師データの付与の解析を行わなければならないため、効率的ではない。	- 過去の画像や解析対象の一部の画像で、サンゴその他の輪郭・色彩(教師データ)を学習させ、インプットとアウトプットの関係性をモデルに学習させる。その学習したモデルを使って、他の画像で判読を行う。  学習データ作成例 - 様々な条件下でのサンゴ形状、色彩を学習してモデルを作成しておけば、1つの学習モデルが使用できる。(ただし、サンゴ画像の大きさは同程度のスケールのものに限る。)
分類精度	分類されたクラス毎に付与させる教師データが多いほど精度が向上する。ダイバーの水中画像ではサンゴとサンゴ以外の2分類80%までの精度が確認されている。今後の実証期間内で枝状サンゴ、その他サンゴ、その他の3分類、精度80%を目指す。	サンゴの画像分類は、初めての試みであり、分類精度は未知数であるが、一般的に、様々な形状や色彩の画像データの学習量が多い分、分類精度が向上するといわれている。

AI（深層学習）による分類の利点は、

- 1) 大きな利点は、既往の手法のように調査回ごとに必要な、クラスタリングと人による教師データの付与が不要であり、**学習モデルが完成すれば、分類したい画像を入力するだけであり、机上での分類解析の時間が短縮できる。**⇒既往の手法の50%の効率化を目指す。
- 2) 分類精度は初めての試みであり、現時点で未知数であるが、**学習データを多くすることで、分類精度が向上する可能性がある。**⇒ドローン撮影や水中曳航カメラ撮影の高精細画像取得と合わせて、3分類(枝状サンゴ、その他サンゴ、その他)、精度80%を目指す。

2 技術開発手法

2.1 検証項目

検証項目と手法を表-VI.6.2.1 に示す。

表-VI. 6. 2. 1 検証項目と手法

項目	検証項目	分類、解析手法
サンゴ計測技術	① ドローン撮影画像によるサンゴ被度計測	・高精度なサンゴ被度分類解析が可能な画像撮影手法について検証する。
	② 船上からの水中カメラ撮影によるサンゴ被度計測	・撮影画像の精度向上、撮影作業の効率化のための画像撮影手法の改善方策を検討し、両手法の有効性を検討する。
サンゴ被度分類技術	① 統計的分類手法による分類	・撮影した画像について、目視観察結果を教師データとして、画像の被度分類解析を行い、目視観察結果と比較して、3 分類以上(枝サンゴ、その他サンゴ、その他)の分類精度を検証する。
	② AI（深層学習）による分類	・AI（深層学習）による分類を上記と同等の分類精度が得られるか、効率性の比較を行い、検証する。 ※「AI モデル」で分類精度 80% の可能性が全く無い、と分かった場合は、AI モデルによる分類手法の技術開発は今後行わない。 ・解析手法の精度向上方策を検討する。

※新規開発技術は、「AI(深層学習)による分類」であり、他は既往技術活用であるが、新規技術開発のために必要な項目である。

2.2 調査位置

①ドローン撮影、船舶曳航水中ビデオ撮影によるサンゴ被度計測

②統計的分類手法とA I 深層学習によるサンゴ被度分類

平成 30 年度に検証を行う調査対象位置図を図-VI.6.2.1 に示す。



図-VI. 6. 2. 1 H30年度調査対象位置図

2.3 調査解析、検討の流れ

平成 30 年度の調査解析、検討のフローを図-VI.6.2.2 に示す。




図-VI. 6. 2. 2 サンゴ被度分類作業フロー (H30 年度)

2.4 調査解析、検討内容

サンゴ被度計測、精度検証の詳細内容を表-VI.6.2.2 に、調査実施のイメージを図-VI.6.2.3 に示す。

表-VI. 6. 2. 2 調査解析及び検討内容 (H30 年度)

作業項目	詳細内容
① 現地撮影, 目視観察	i) ドローン撮影 ・ 100m×100m の調査対象範囲を 50m 高度で面的に撮影するようプログラムする。 ・ 強風が吹かない静穏な日に、船上よりドローンを飛行させ画像撮影。 ii) 船上からの水中ビデオ撮影 ・ 水中カメラを調査船舷側に水中カメラを海底向きに固定し艀装する。 ・ 船上で GNSS 誘導により調査測線を航走しながら、海底(サンゴ礁域)をビデオ撮影。 iii) 潜水目視観察 ・ 画像撮影と同時期に、サンゴの同定ができる専門家による潜水目視観察を実施 ・ 測線上 10m の間隔で水深、底質状況、サンゴの種ごとの被度を観察
② 画像処理	・ 画像のオルソ化を行うためのドローン撮影の静止画像に位置座標を与える。水中ビデオ撮影のキャプチャー画像を連続的な画像となるよう抽出する。 ・ ドローン撮影の静止画像及び水中ビデオ撮影画像のキャプチャー画像をつなぎ合わせ、ドローン撮影画像はオルソ(正射投影)画像、水中カメラ画像はモザイク画像を作成する。 ・ ドローン撮影画像の場合は、底質による水深補正を行う。
③ サンゴ分類解析 ※H30 年度はドローン画像または水中カメラ画像でより適切なオルソ画像	【既往の分類解析手法】 ・ オブジェクト分類：1 画素ではなく、画像内で隣接するピクセルどうしの比較的均質な画素のまとまり（オブジェクト）を最小単位として分類する。 ・ 教師データ抽出：底質区分ごとに、現地目視観察位置のサンゴ被度又は有無を、同じオブジェクト分類箇所に付与して教師データとする。 ・ サンゴ分類解析：教師データをもとに、すべてのオブジェクトに対して被度分類解析を行う。 【AI モデルによる分類解析】 ・ AI 学習モデルの構築：撮影した画像に対し、サンゴ(枝状・塊状)、底質などの教師データを与えて、学習させ、深層学習モデルを構築する。 ・ AI 学習モデルによる、撮影画像のサンゴ自動分類：学習モデルを用いて画像全体に対してサンゴの自動分類解析を行う。
④ 課題の抽出 (精度検証、効率性の検討)	・ 「既往の手法」と「AI モデル」による分類解析結果と目視観察結果との精度検証を行い、分類手法の違いによる精度の比較及び、作業の効率性を比較して、手法の優位性の検討を行う。 ・ 同じ分類手法で行った場合の、ドローンと船上からの水中ビデオ画像による観測方法との違いによる、精度の評価を行う。 ・ 精度検証結果及び効率性の比較に基づき、撮影(画像取得)方法、分類解析方法の改善に向けての課題の抽出を行う。
⑤ 次年度の計画	・ 課題の抽出をうけて、次年度の精度向上方策（撮影手法、分類解析手法）を計画する。

表-VI. 6. 2. 3 使用したカメラ精度

	ドローン	船舶水中カメラ
機種名	DJI 製 Phantom4 Pro	Woodman Labs 製 Gopro hero6
撮影区分	静止画 (0.5 枚/秒)	動画 (30 枚/秒)
撮影画像	1768 万画素 (4856×3640pix)	276 万画素 (1920×1440pix)



精度検証用目視観察の状況 (H30 年 5 月下旬)



画像撮影用ドローン (DJI 社 Phantom 4 Pro)



ドローン撮影操作状況 (H30 年 6 月初旬)



ドローン飛翔撮影状況 (H30 年 6 月初旬)



船舶取付け水中カメラ撮影状況



水中カメラの外観 (GoPro 社製カメラ)

図-VI. 6. 2. 3 調査実施状況

2.5 実施工程

平成 30 年度の実施工程を表-VI.6.2.4 に示す。

表-VI. 6. 2. 4 H30 年度実施工程表

H30 年度 実施項目	5 月	6 月	7 月	8 月	9 月	10 月	11 月	12 月	1 月	2 月	3 月
計画準備	■										
現地撮影, 目視観察	■	■									
画像処理		■	■	■	■	■					
サンゴ分類解析						■	■	■	■	■	
課題の抽出(精度検証)									■	■	■
次年度の計画										■	■

3 調査・解析結果

3.1 計測効率化の検証

今回実施した「ドローン撮影」及び「船舶水中カメラによる撮影」が従来の「潜水士による水中ビデオ撮影」と比較し計測時間の効率化が図れたかについて、現地の撮影時間から検討した。

検討した作業効率を以下の表-VI.6.3.1 に示す。

潜水士による水中ビデオ撮影と比べ、ドローンによる撮影では 6 倍、船舶水中カメラによる撮影では 3.5 倍の効率化を図ることができた。

表-VI. 6. 3. 1 サンゴ被度計測の効率化検討結果

撮影手法	作業日数
① ドローンによる撮影	撮影面積：100m×100m＝1ha 1ha 撮影の所要時間：2.0 時間 1 時間当たりの撮影可能面積：0.5ha 1 日(7.5 h)当たりの撮影可能面積：3.75ha <u>10ha 撮影に必要な日数：約 3 日間</u>
② 船舶水中カメラによる撮影	撮影面積：3m×100m＝0.03ha 0.03ha 撮影の所要時間：0.12 時間 1ha 撮影の所要時間：4.0 時間 1 時間当たりの撮影可能面積：0.25ha 1 日(7.5 h)当たりの撮影可能面積：1.88ha <u>10ha 撮影に必要な日数：約 5 日間</u>
参考値 潜水士による水中ビデオ撮影	撮影面積：100m×100m＝1ha 1ha 撮影の所要時間：13.8 時間 1 時間当たりの撮影可能面積：0.07ha 1 日(7.5 h)当たりの撮影可能面積：0.53ha <u>10ha 撮影に必要な日数：約 18 日間</u> ※有性生殖によるサンゴ増殖の手引き 技術ノート 3 水中ビデオ画像によるサンゴ自動分類技術を参考に計算した。

3.2 分類効率化の検証について

AI による分類の効率化については、本年度初年度の試みのため、AI モデルの選定、教師データの抽出、学習手法などの作業方法の試行錯誤の約 5 ヶ月にわたる検討により、初期解析にかなりの時間を要し、教師データ抽出、学習、分類の各作業の所用時間の計測は

行えなかったが、今年度、分類解析の手法が概ね確立できたため、今後は、教師データをさらに学習させ、新しい画像でも解析時間を必要としないモデルを作成することをめざしており、本実証試験の最終段階で 50%の効率化を目指す。

3.3 ドローン撮影画像によるサンゴ被度計測結果

ドローン撮影結果のオルソ画像は図-VI.6.3.1 に示すとおりである。

現地では、撮影高度 30m と 50m の 2 パターンで撮影したが、30m 高度撮影では、写真同士をつなげる特徴点が減り、オルソ化ができなかった。

一方、撮影高度 50m の画像は 100m×100m の範囲を概ねオルソ化できた。

ただし、水深 4m 以深の海底地形が不明瞭な一部エリア（C 付近）は、写真同士をつなげる特徴点が少なくオルソ化できなかった。


次に、ドローン撮影結果等の拡大画像は図-VI.6.3.2 に示すとおりである。

ここに示すように、ドローン画像は水面の波によりサンゴ個々の輪郭が不明瞭となってしまった。

当初 AI によるサンゴ分類を行う予定であったが、解析対象物が不明瞭な場合、AI の解析にはそぐわないため、ピクセルベースでの統計的分類により解析を行った。

表-VI. 6. 3. 2 分類手法別の特性とメリット、デメリット

統計的分類手法	AI による分類手法
【分類手法】 現地調査結果を参考にした教師付き分類手法、教師なし分類手法による画像分類	【分類手法】 解析対象の一部画像で、サンゴ・その他について学習させて、インプットとアウトプットの関係性をモデル化する。そのモデルを使って画像を分類する。
【メリット】 手法が簡便であるため画像分類の実施が容易である。	【メリット】 さまざまな条件下での画像を学習することで、汎用性の高いモデルが構築され、さまざまなパターンの画像に適用できる。
【デメリット】 調査1回の画像に対して都度画像分類処理を行う必要がある。複数回ある場合、その都度パラメータを調整して画像分類を行う必要があるため効率的ではない。	【デメリット】 大量の学習用データが必要になる。



撮影日時: 2018 年 6 月 6 日
撮影高度: 水面上 50m




図-VI. 6. 3. 1 ドローン撮影結果のオルソ画像




図-VI. 6. 3. 2 撮影結果の拡大画像比較

3.4 ドローン撮影画像によるサンゴ被度分類結果

ドローン撮影画像によるサンゴ被度分類結果は図-VI.6.3.3 に示すとおりである。

分類は、ノル等水深約 2～3m よりも浅い浅場のサンゴ被度に対し解析できた。一方、参考となる現地調査結果が浅場の高被度部分に集中したため、低被度部分や約 2～3m よりも深い箇所の被度分類ができなかった。また、解析可能な水深は、空中からの撮影であり、海域の濁り具合や、海中の画像にゆらぎが生じる波高にも大きく依存するため、一概には解析可能水深は今回の調査結果からは判断することは困難である。

よって、被度のバリエーションに富んだ現地調査データかつ、現在の 10m ピッチの観察結果より細かいスケールでの被度に関する情報を取得する必要がある。

さらに、自動飛行機能を有したドローンで、より高高度で撮影することにより各撮影画像に多くの特徴点を入れ、オルソ化できる範囲を増やす必要がある。




図-VI. 6. 3. 3 ドローン撮影画像のサンゴ被度分類結果

3.5 船舶水中カメラ撮影によるサンゴ礁観測結果

船舶水中カメラ撮影結果のオルソ画像は図-VI.6.3.4、図-VI.6.3.5 に示すとおりである。

水中カメラ撮影画像はサンゴ個々がわかる精細な画像でオルソ化ができた。

一方、船が風や潮流により流されるため測線上を真っ直ぐ移動することが難しく、計測に時間を要するという問題点が生じた。




図-VI. 6. 3. 4 船舶水中カメラ撮影結果




図-VI. 6. 3. 5 水中カメラ撮影結果のオルソ画像

3.6 船舶水中カメラ撮影によるサンゴ被度分類結果

船舶水中カメラ撮影画像に対して、「AI モデルによる分類手法」と従来の「統計的分類手法（オブジェクトベース分類）」でサンゴ分類を実施した。

【オブジェクトベース分類による統計的分類手法】

教師付き分類のひとつであるオブジェクトベース分類を実施。領域分割によって得られる空間的に比較的均質な画素のまとまりに区分（オブジェクト）した後、教師を付与し、画像分類を行う。




図-VI. 6. 3. 6 オブジェクトベース分類によるサンゴ分類手順

【AI モデル（深層学習）による分類手法】

インスタンスセグメンテーション手法の一つ Mask R-CNN（物体検出と分類の一手法）により実施。下図のように物体ごとに領域を抽出する。物体検出のアルゴリズムが基本になっているが、下図のように物体ごとの矩形（枠）・クラスに加えて、物体の領域も抽出する。




図-VI. 6. 3. 7 インスタンスセグメンテーションの概要¹


オルソ化した画像の北側半分の領域を教師データとして用いた。

北側領域において、サンゴ、岩盤、砂礫等、約 1,500 個をラベリングした内、サンゴを教師データとして学習させた。（上記データから 600 枚の 200×200pixel 画像パッチを作成し学習）
分類数 5 区分と 2 区分で実施した。

5 区分：パラオハマサンゴ、スギノキミドリイシ、ナンヨウミドリイシ、ハナガサミドリイシ・コユビミドリイシ、非サンゴ

2 区分：サンゴ、非サンゴ

南側の 2 箇所を検証用データとした。



¹ Kaiming He, Georgia Gkioxari, Piotr Dollár, Ross Girshick. Mask R-CNN. <https://arxiv.org/abs/1703.06870>

船舶水中カメラ撮影によるサンゴ被度分類結果は図-VI.6.3.8 に示すとおりである。

その結果、「従来のオブジェクトベース分類」と同程度に「AI モデルによる分類」により主要なサンゴの抽出がある程度できた。

一方、小さいサンゴや出現頻度が低いサンゴ種の分類ができておらず、種分類はほぼできていなかった。また、2 分類はある程度サンゴの分類ができているが、形状の正確な抽出に課題が見られた。

次に、各分類の分類精度について、表-VI.6.3.4、図-VI.6.3.9 に示した。

「従来のオブジェクトベース分類」、「AI モデルによる分類」ともに全体精度は 80%以上となった。ただし、個々の分類精度について、5 分類では、最も出現頻度が高かったハナガサミドリイシ・コユビミドリイシは 57%であるがその他のサンゴは 0~21%と抽出できていなかった。2 分類でもサンゴの分類精度は 53%となった。

表-VI.6.3.4 に示したとおり、学習個数が比較的多い対象で分類精度が高まる傾向が見られた。




図-VI. 6. 3. 8 (1) 水中カメラ撮影結果のオルソ画像に対する AI 画像分類解析結果





図-VI. 6. 3. 8 (2) 水中カメラ撮影結果のオルソ画像に対する AI 画像分類解析結果

表-VI. 6. 3. 4 手法別の分類精度

分類	プロデューサー精度	解析区分	
		オブジェクトベース分類	AIによる分類
5分類	パラオハマサンゴ	18%	21%
	スギノキミドリイシ	2%	0%
	ナンヨウミドリイシ	0%	0%
	ハナガサミドリイシ、コユビミドリイシ	51%	57%
	非サンゴ	98%	97%
	全体精度	87%	88%
	kappa係数	0.48	0.50
2分類	サンゴ	51%	53%
	非サンゴ	97%	99%
	全体精度	88%	92%
	kappa係数	0.55	0.62

全体精度は 80% 以上となったが、サンゴの分類は 0～50% 程度となった。



※車載画像の既往事例は、あくまで一例であり、必ずしもサンゴの分類において同様の精度となるわけでは無い。

- 1) 全体精度:対象地の被度の中で、正しく画像分類された割合を表す比。(正しい分類面積/総面積)
- 2) Kappa 係数:1 から-1 の値をとり、1 に近いほど予測結果が良いとされ、0 以下は偶然の一致とされる。Landis JR, Koch GG(1977)の基準によれば、0. 41～0. 60 は中程度の一致、0. 61～0. 80 は高度の一致、0. 81～1. 00 はほぼ完全な一致とされる。

図-VI. 6. 3. 9 教師の学習個数と分類精度の関係

4. 結果のまとめと今後の課題

● 結果, ⇒課題

【ドローン撮影によるサンゴ被度計測・分類】

- 従来の潜水土撮影と比較し、6 倍の作業効率で撮影ができた。(3.57ha/日)
- 撮影高度が低い場合(水面上 30m)や水深 4m 以深の海底地形が不明瞭な場合は、写真同士をつなげる特徴点が少なくなりオルソ化ができなかった。
⇒自動飛行機能を有したドローンを用い、より高高度で撮影することにより各撮影画像に多くの特徴点を入れ、対象範囲すべてをオルソ化できるよう改善する。ただし、分類するために必要な画素数と撮影高度の関係も合わせて検討する。
- ドローン撮影は水面の波によりサンゴ個々の輪郭が不明瞭のため、AI による分類より、ピクセルベースの統計的分類が適していた。
- ノル上のサンゴ被度分類が実施できた。一方、参考となる現地調査結果が高被度部分に集中したため、低被度部分の特定ができなかった。
- ドローンによる撮影は従来の航空機による撮影画像と同じように空中写真撮影であるため、海域の濁りや波高によって海中のサンゴ被度解析の精度に影響を及ぼす。可能な限り透明度や海象の条件の良い撮影日を選定し、かつ、海底底質ごとの現地検証データを取得することで深い場所でのサンゴ被度解析の精度を高める必要がある。
⇒被度のバラエティーに富んだ教師データかつ、現在の 10m ピッチの観察結果により細かいスケールの教師データを取得し、分類精度向上を目指す。

【船舶水中カメラ撮影によるサンゴ被度計測・分類】

- 従来の潜水土撮影と比較し、3.5 倍の作業効率で撮影ができた。(1.88ha/日) ただし、船が風や潮流により流されるため測線上を真っ直ぐ移動することが難しいという問題点が生じた。
⇒船舶水中カメラ撮影の効率化について、計画測線上を航行する際に水中カメラ撮影範囲内に計画測線のロープが写るように正確かつ速やかに操行する技術を開発する。
- ⇒サンゴの生息分布を面的に効率よく把握する場合、全海底面を把握する必要はなく、撮影測線の間隔を適度に広げて計測の効率化を図ったうえで、広域のサンゴ生息分布を推定する。ただし、この場合においても、撮影画像を自動的につなぎ合わせるオルソ化の際に、計画測線ロープなど目印となるものが必要であり、上記の課題のとおり目印が映りこむように計画測線上を撮影する必要がある。
- サンゴの個々がわかる精細な画像でオルソ化ができた。よって、AI による分類、オブジェクトベースの統計的分類を行った。両分類手法とも全体精度 80%以上となり、個々の分類精度は 0~57%となった。学習個数が多い対象ほど分類精度が高まった。
⇒新たなサンゴ礁画像を取得し、教師データを増やすことで、さらなる分類精度向上を目指す。

5. 次年度の計画

(1) サンゴ計測技術

① ドローン撮影画像によるサンゴ被度計測

自動飛行機能を有したドローンによる浦底湾(100m×100m 範囲)撮影

ハレーションのない部分を抽出するためラップ率高めて撮影

② 船舶水中カメラ撮影によるサンゴ被度計測

- ・ドローン撮影範囲内を撮影

- ・撮影画像のオルソ化を適切に行うため、航行する際に、水中カメラ撮影範囲内に計画測線のロープが写るよう位置精度を保ちつつ、速やかに航走する技術を開発する。

(2) 計測場所：浦底湾及び沖ノ島

各計測技術の調査地点設定の考え方は以下のとおりである。

① ドローン撮影：ドローン撮影高度から特徴的な地形を多く含み、撮影範囲内に、サンゴ高被度、低被度の箇所を含めて設定する。

② 船舶水中カメラ撮影：サンゴ生息分布を面的に効率よく把握する場合、全海底面を把握する必要はなく、撮影測線の間隔を適度に広げて計測の効率化を図ったうえで、広域のサンゴ生息分布を推定する。

※次年度の現地調査前に、地形情報及び地点状況の確認を行ったうえで、考え方に沿った地点配置を選定する。



図-VI. 6. 5. 1 次年度の沖縄沿岸域（浦底湾）調査箇所の案

(3) サンゴ被度分類技術

① 統計的分類手法による分類

② AI（深層学習）による分類

①②ともに被度のバラエティーに富んだ教師データを増やし、分類精度向上を目指す。また、AIによる分類では2019年度については、2分類において個々の分類精度80%以上を目指すとともに、従来の統計的分類の分類作業の効率化50%を目指す。