

## IV-5. 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-5	ICT 技術等を活用したサンゴの被度計測技術の開発	
1.	目的	IV-5-1-1
2.	技術開発手法	IV-5-2-1
2.1	検証項目	IV-5-2-1
2.2	調査位置	IV-5-2-2
2.2	調査解析、検討の流れ	IV-5-2-3
3.	調査・解析結果	IV-5-3-1
3.1	サンゴ被度分類結果	IV-5-3-1
3.2	分類作業の効率化の検証	IV-5-3-18
3.3	考察	IV-5-3-20
4.	結果のまとめ	IV-5-4-1
5.	次年度の計画（案）	IV-5-5-1

## IV-5 ICT 技術等を活用したサンゴの被度計測技術の開発

### 1 目的

広範囲のサンゴの分布を把握する手法として、船上水中カメラやリモコンボートを活用した効率的観測手法と、人工知能 (AI) を活用した効率的な解析手法の技術の開発を行う。

#### (1) サンゴ計測技術

令和 4 年度は沖ノ鳥島海域において、手振れ補正機能が向上したカメラを使用した高精度化の試行を行った。手振れ補正機能が向上したカメラを使用することで動画 (60 フレーム/秒) の切り出し画像でもブレの少ない画像を取得でき、また、撮影時のカメラ設定を自動露出補正無しで撮影することで、“白飛び” が少なく、サンゴの色情報を捉えられる画像を取得できた。画像合成方法は、リモコンボートの測線方向に隣り合う画像同士をパノラマ写真のようにつなぎ合わせるモザイク処理による合成を行うことで、処理前の元の画像の視認性を維持し、効率的に合成画像を作成できた。

上記手法でのサンゴ計測を沖ノ鳥島海域では令和 3 年度から実施しており、「質の高い教師データの蓄積」が課題となっている。

そこで、令和 5 年度は沖ノ鳥島海域において質の高い教師データを作成するため、継続して同じ撮影方法により画像を取得し、AI 学習モデルのサンゴ分類の高精度化の検証を行う。

#### (2) サンゴ分類技術

令和 4 年度は沖ノ鳥島海域において質の高い教師データを増やし解析を行った。その結果、過年度に比べて 2 分類の分類精度は、2022 年単年、2019～2022 年複数年のいずれの学習モデルにおいても、過年度と同程度の分類精度であり、事業計画目標とする分類精度 80%は未達成であった (表-IV. 5. 1. 1)。AI 分類精度が向上しない要因としては、「モザイク画像の色調の暗い部分で誤分類している」ことが考えられた。

一方、実証海域 (沖縄) では、①モザイク画像の標準化、②死サンゴの教師データの追加を行い、検証を行った。その結果、2 分類の分類精度は事業計画目標とする分類精度 80%を達成 (82%) した (表-IV. 5. 1. 2)。また、サンゴ種別においても、コリンボース状は事業計画目標を達成 (85%) し、樹枝状サンゴも概ね達成 (79%) した。

そこで、令和 5 年度は、実証海域 (沖縄) における AI 解析結果を踏まえ、沖ノ鳥島海域の令和 3 年度 (2021 年)、令和 4 年度 (2022 年) に撮影したモザイク画像を用いて、「教師エリアの拡大による教師データの追加」や、「モザイク画像の標準化」を行い、サンゴ分類の高精度化の検証を行う。

表-IV.5.1.1 過年度分類精度の検証結果（沖ノ鳥島海域）

分類	プロデューサー精度	2019年	2020年	2021年	2022年	2019～ 2022年
サンゴ 6分類+ 非サンゴ	樹枝状 (Acropora doneiなど)	0%	16%	検証データに存在しない	検証データに存在しない	-
	コリンボース状 (ハリダミドリイシなど)	84%	69%	72%	49%	
	被覆状 (コモンサンゴ属など)	1%	0%	50%	4%	
	塊状 (キクメイシ属・ハマサンゴ属など)	31%	54%	43%	60%	
	格子模様あり塊状 (マルキクメイシなど)	7%	0%	6%	1%	
	その他サンゴ	検証データに存在しない	0%	1%	検証データに存在しない	
	非サンゴ	99%	98%	96%	99%	
	全体精度	95%	92%	90%	98%	
	kappa係数	0.5	0.55	0.63	0.59	
2分類	サンゴ	49%	56%	65%	56%	57%
	非サンゴ	98%	95%	97%	99%	99%
	全体精度	95%	91%	92%	97%	97%
	kappa係数	0.53	0.53	0.68	0.57	0.58

※黒字：令和3年度以前の過年度の成果

赤字：令和4年度の成果

表-IV.5.1.2 過年度分類精度の検証結果（沖縄海域）

分類	プロデューサー精度	2020～2021年	
		過年度手法	今年度手法
個別分類	樹枝状 (スギノキミドリイシなど)	73%	79%
	コリンボース状 (ハカザミドリイシ、ユビミドリイシなど)	80%	85%
	テーブル状 (クシハダミドリイシなど)	64%	66%
	塊状 (ハマサンゴ属など)	0%	88%
	その他サンゴ	19%	
	非サンゴ	91%	
	全体精度	83%	85%
	kappa係数	0.68	0.71
2分類	サンゴ	79%	82%
	非サンゴ	88%	90%
	全体精度	85%	87%
	kappa係数	0.67	0.72

※黒字：令和3年度以前の過年度の成果

赤字：令和4年度の成果

## 2 技術開発手法

### 2.1 検証項目

検証項目と手法を表-IV.5.2.1 に示す。

表-IV.5.2.1 検証項目と手法

項目	検証項目	検証手法
サンゴ計測 技術 (沖ノ鳥島の のみ)	<ul style="list-style-type: none"> <li>リモコンボート取付水中カメラ撮影によるサンゴ被度計測</li> </ul>	<ul style="list-style-type: none"> <li>高機能の撮影カメラ（手振れ補正機能向上）で撮影を行い、撮影画像の高精度化（ブレや白飛びを抑えた画像取得）の検証</li> <li>沖ノ鳥島でよくみられるサンゴ（コリンボース状サンゴ（ハリエダミドリイシ等）、塊状サンゴ（ハマサンゴ等）など）が分布するエリアに測線を設定・撮影し、学習データ蓄積を図ることで、AI 学習モデルのサンゴ分類の高精度化の検証</li> </ul> <div style="text-align: center;">  <p>ハリエダミドリイシ      globiceps</p> </div> <ul style="list-style-type: none"> <li>（昨年度までの実績において、10ha を 3.3 日で撮影でき、効率化の目標を達成している）本年度も継続して撮影作業の効率を検証</li> </ul>
サンゴ分類 技術	<ul style="list-style-type: none"> <li>AI（深層学習）による分類</li> </ul>	<ul style="list-style-type: none"> <li>（昨年度行った沖縄海域の AI 解析結果を踏まえ）2021 年、2022 年の画像を用いて、教師エリアの拡大による教師データの追加や過年度作成データの見直し、モザイク画像の標準化を行い、サンゴ分類の高精度化を検証</li> <li>上記の分類作業の実績から、分類作業の効率化を検証</li> </ul>

## 2.2 調査位置

過年度の潜水観察でコリンボース状や塊状サンゴが確認されたL-5-3測線周辺において、2022年の衛星画像解析の結果を参考にしながら、サンゴの被度が高いエリアで撮影する(100m×5測線程度)計画を行った。計画した調査対象位置図を図-IV.5.2.1、図-IV.5.2.2に示す。

なお、今年度の現地調査は、台風の影響により実施できなかった。



図-IV.5.2.1 令和5年度測線設定位置

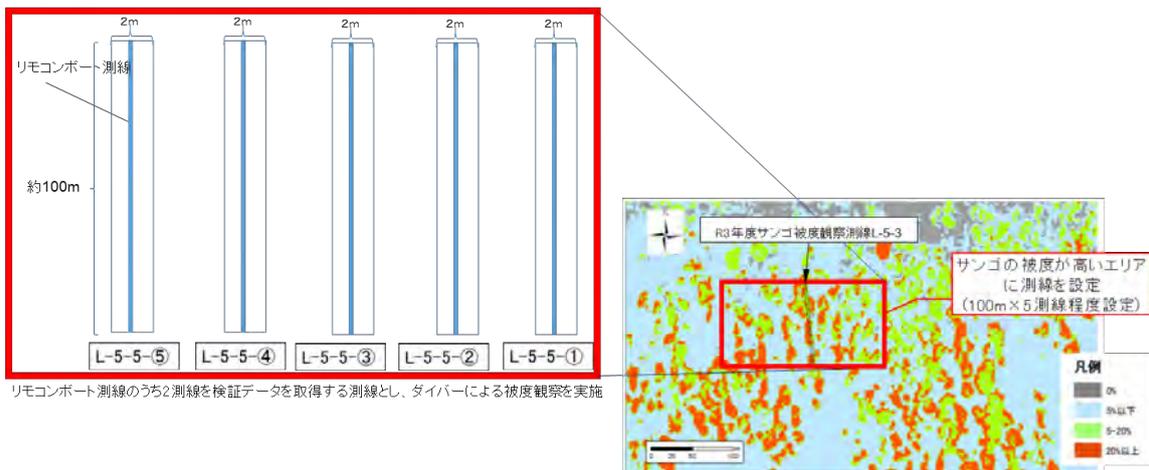


図-IV.5.2.2 沖ノ鳥島衛星画像解析結果と撮影測線のイメージ

## 2.3 調査解析、検討の流れ

令和5年度の調査解析、検討のフローを図-IV.5.2.3に示す。

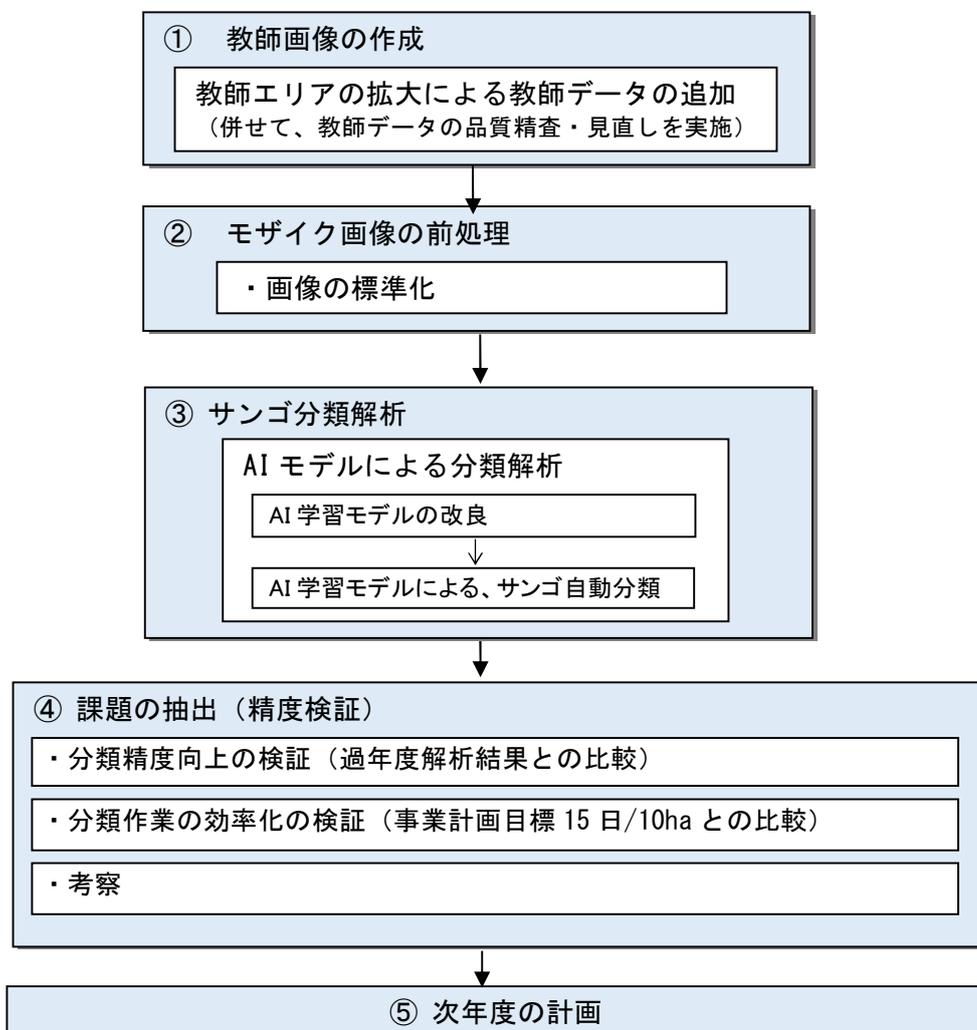


図-IV.5.2.3 サンゴ被度分類作業フロー

### 3. 調査・解析結果

#### 3.1 サンゴ被度分類結果

沖ノ鳥島の中水カメラ撮影画像に対して、「AI モデルによる分類手法」によりサンゴ分類を実施した。

##### (1) 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）により実施した。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。

昨年度までの手法と同様に、サンゴ 1 種類ごとに学習するモデルを構築した。

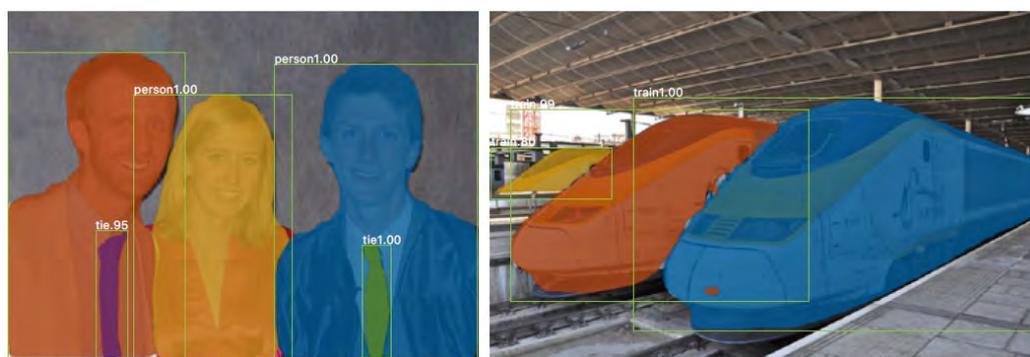


図-IV.5.3.1 インスタンスセグメンテーションの概要<sup>1</sup>

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

[2] Zhaojin Huang et, al. Mask Scoring R-CNN

## (2) 教師エリアの拡大

教師データは、2021年、2022年撮影画像を用いて、図-IV.5.3.2、図-IV.5.3.3の黄枠領域内で追加作成するとともに、過年度作成したデータの品質の精査を行い、一部見直しを行った。

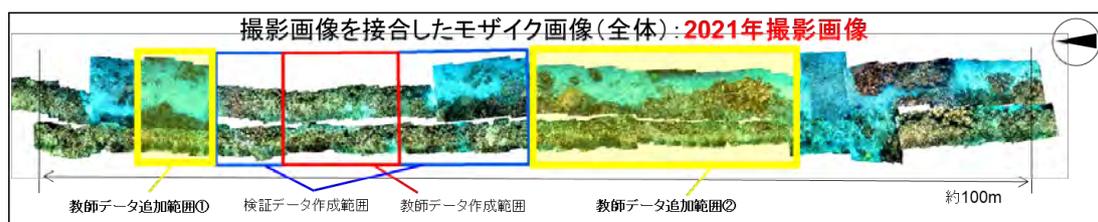


図-IV.5.3.2 教師・検証データ作成範囲（2021年）

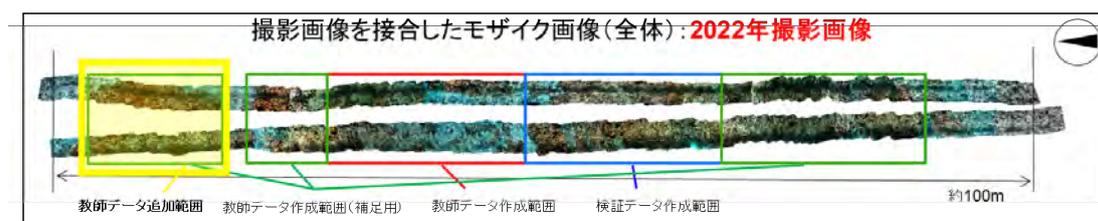


図-IV.5.3.3 教師・検証データ作成範囲（2022年）

## (3) モザイク画像の前処理

1枚に結合する前のモザイク画像は、撮影時の光条件や映り込んだ対象物により、色調の違いが生じる。そのため、標準化（特徴量のスケールを揃える手法）により影響を緩和させたくて1枚に接合を行った。

標準化を行うことで、画像の明るい部分が抑えられ、暗い（色が濃い）部分が明るくなることが確認された。

調整の結果を図-IV.5.3.4、図-IV.5.3.5に示す。

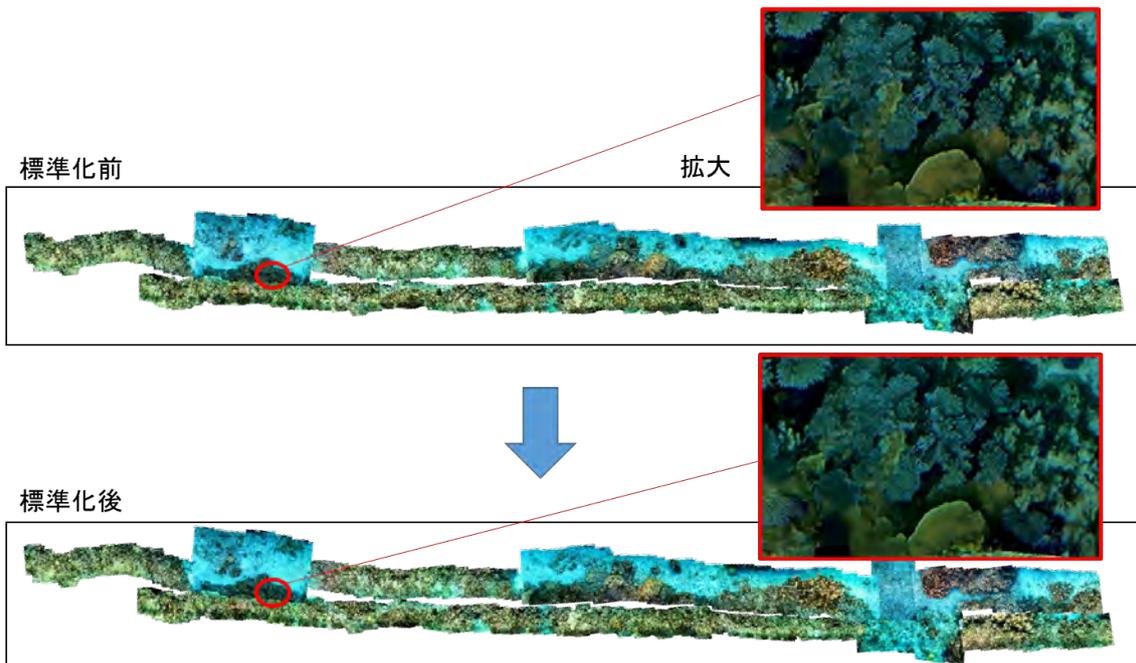


図-IV.5.3.4 標準化前後の画像（2021年）

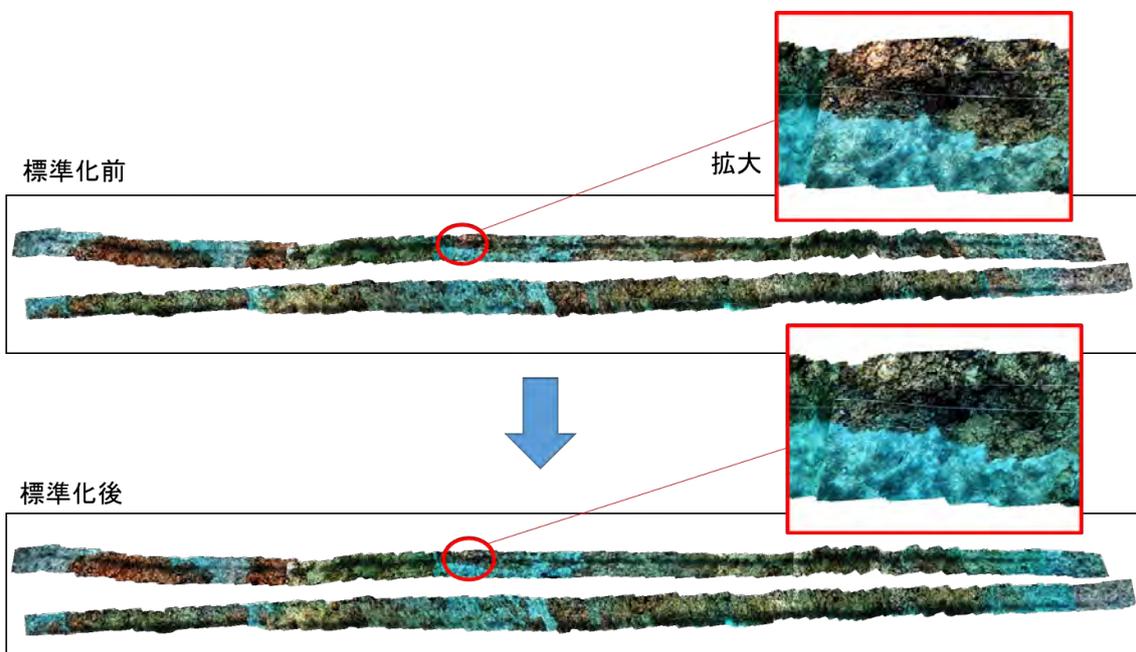


図-IV.5.3.5 標準化前後の画像（2022年）

(4) 教師・検証データの作成

沖ノ鳥島のサンゴの教師データは、サンゴの形状の違いから以下の6分類とした。  
表-IV.5.3.3には教師データを作成したサンゴのイメージ写真を示す。

表-IV.5.3.3 (1) 沖ノ鳥島におけるサンゴ分類

サンゴ分類	イメージ写真 (2019・2020年観察調査写真より)
樹枝状 (Acropora donei など)	Acropora donei 
コリンボース状 (ハリエダ ミドリイシ、 Acropora globiceps など)	ハリエダミドリイシ  Acropora globiceps 

表-IV.5.3.3 (2) 沖ノ島島におけるサンゴ分類

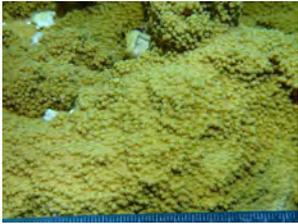
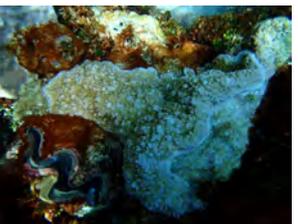
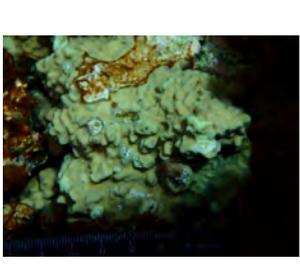
サンゴ分類	イメージ写真 (2019・2020年観察調査写真より)		
被覆状 (コモンサンゴ属、リュウキュウキツカサンゴ、アミメサンゴ属など)	シモコモンサンゴ		
			
	トゲコモンサンゴ		
			
	モリスコモンサンゴ		
			
			
	アミメサンゴ		
			
	アミメサンゴ属		
			

表-IV. 5. 3. 3 (3) 沖ノ鳥島におけるサンゴ分類

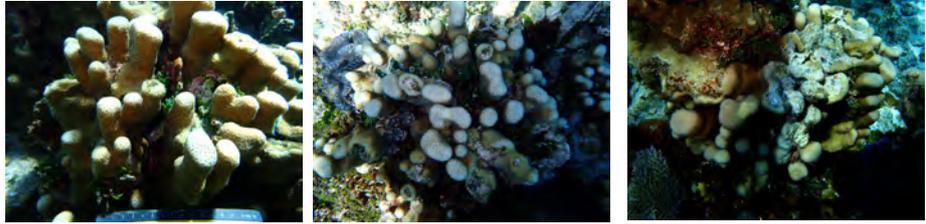
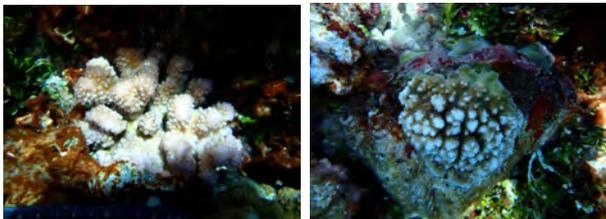
サンゴ分類	イメージ写真 (2019・2020年観察調査写真より)		
塊状 (キクメイシ属、ハマサンゴ属、ナガレサンゴ、オオサザナミサンゴ、ミダレノウサンゴ)	ホシキクメイシ		
			
	コトゲキクメイシ		
			
	トゲキクメイシ属		
			
	トゲキクメイシ		
			
	ベニハマサンゴ		
			
オオハマサンゴ			
			

表-IV.5.3.3 (4) 沖ノ鳥島におけるサンゴ分類

サンゴ分類	イメージ写真 (2019・2020年観察調査写真より)		
塊状 (続き)	ハマサンゴ属		
			
	ナガレサンゴ		
			
	オオサザナミサンゴ		
			
	ミダレノウサンゴ		

表-IV.5.3.3 (5) 沖ノ鳥島におけるサンゴ分類

サンゴ分類	イメージ写真 (2019・2020年観察調査写真より)
格子模様あり塊状 (コカメノコキクメイシ、マルキクメイシ、ウスチャキクメイシ)	コカメノコキクメイシ 
	マルキクメイシ 
	ウスチャキクメイシ 
その他サンゴ	主なその他サンゴの一部 オオカメノコキクメイシ   シワシコロサンゴ   ハマシコロサンゴ  ハナヤサイサンゴ属   クシハダミドリイシ 

作成したサンゴの教師データ数は、以下に示す。新たに教師データを追加したことにより、AI に読み込ませた教師データ数は、2022 年単年モデルのコリンボース以外は、過年度と比較して 2 倍以上となった。

表-IV. 5. 3. 4 AI に読み込ませた教師データ数の過年度・今年度の比較

サンゴ種	2021 年単年モデル		2022 年単年モデル		2021+2022 年 複数年モデル	
	過年度	今年度	過年度	今年度	過年度	今年度
樹枝状	0	0	0	0	-	0
コリンボース状	168	566	93	101	-	667
被覆状	77	155	13	33	-	188
塊状	236	618	400	975	-	1593
格子模様あり塊状	27	40	21	64	-	104
その他	64	20	3	1	-	21
合計	572	1399	530	1174	-	2573

AI 解析は下記の分類で解析を行った。

個別分類：(サンゴ 6 分類+非サンゴ)：

- 樹枝状 (Acropora donei など)
- コリンボース状 (ハリエダミドリイシなど)
- 被覆状 (コモンサンゴ属など)
- 塊状 (キクメイシ属・ハマサンゴ属など)
- 格子模様あり塊状 (マルキクメイシなど)
- その他サンゴ
- 非サンゴ

2 分類：サンゴ、非サンゴ

## (5) 被度分類解析結果・分類精度のまとめ

(1)～(4)の作業を行った AI モデルを用いて、検証エリアにおけるサンゴの 2 分類の解析結果を図-IV.5.3.6～図-IV.5.3.8 に、個別分類の解析結果を図-IV.5.3.9～図-IV.5.3.11 に示す。図には比較のため、過年度の解析結果も併せて示す。

分類精度について、過年度と今年度（単年、複数年の学習モデル）を比較し整理した結果を表-IV.5.3.5 に示す。

### 【2分類】

- 2021 年、2022 年撮影画像ともに単年モデルでは、サンゴの分類精度が過年度より高くなった
- 2021+2022 年複数年モデルでは、単年の学習モデルと比べて、どちらの撮影画像で検証した場合も概ね横ばい

### 【個別分類】

- 2021 年、2022 年撮影画像ともに単年の学習モデルでは、精度が過年度より高くなるサンゴ種が複数あった
  - 2021+2022 年複数年モデルでは、2021 年撮影画像を用いて検証した結果、コリンボース状は 80%を達成し、塊状も精度が向上
  - 2022 年撮影画像を用いた検証では、目標には未達であったが、分類精度が向上し、塊状で 70%程度に達した。
- ⇒ 複数年モデルにすることで、精度が向上し、コリンボース状の分類精度において、事業計画目標の 80%を達成

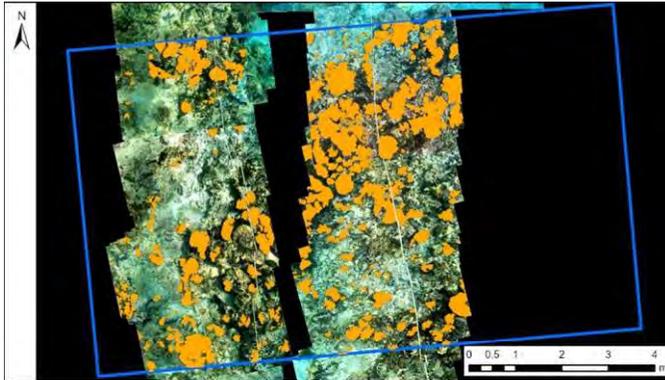
表-IV.5.3.5 分類精度の過年度、今年度（単年、複数年の学習モデル）の比較

分類	プロデューサー精度	2021年撮影画像で検証			2022年撮影画像で検証		
		2021年	2021年	2021年 +2022年	2022年	2022年	2022年 +2021年
サンゴ 6分類+ 非サンゴ	樹枝状 (Acropora doneiなど)	検証データに存在しない	検証データに存在しない	検証データに存在しない	検証データに存在しない	検証データに存在しない	検証データに存在しない
	コリンボース状 (ハリダミドリイシなど)	72%	78% ↑	84% ↑	49%	42%	62% ↑
	被覆状 (モモサンゴ属など)	50%	28%	42%	4%	5% ↑	20% ↑
	塊状 (キクメイシ属・ハマサンゴ属など)	43%	57% ↑	68% ↑	60%	61% ↑	68% ↑
	格子模様あり塊状 (マルキクメイシなど)	6%	10% ↑	0%	1%	7% ↑	14% ↑
	その他サンゴ	1%	十分な検証データに存在しない	十分な検証データに存在しない	検証データに存在しない	十分な検証データに存在しない	十分な検証データに存在しない
	非サンゴ	96%	97%	97%	99%	99%	96%
	全体精度	90%	93%	94%	98%	97%	95%
	kappa係数	0.63	0.72	0.76	0.59	0.54	0.45
2分類	サンゴ	65%	72% ↑	72%	56%	57%	57%
	非サンゴ	97%	97%	97%	99%	99%	95%
	全体精度	92%	93%	93%	97%	97%	93%
	kappa係数	0.68	0.72	0.72	0.57	0.57	0.35

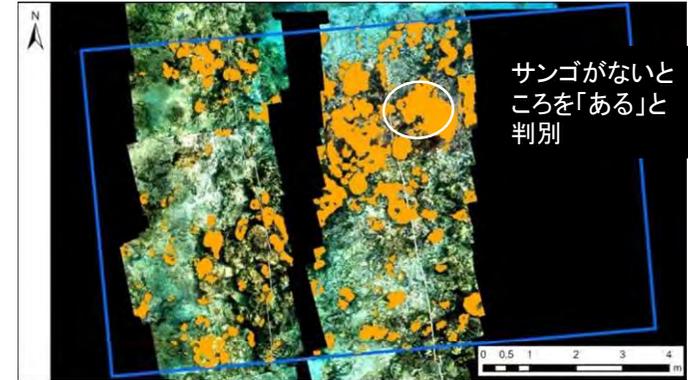
全体精度:対象地の被度の中で、正しく画像分類された割合を表す比。(正しい分類面積/総面積)  
 Kappa 係数:1 から-1 の値をとり、1 に近いほど予測結果が良いとされ、0 以下は偶然の一致とされる。Landis JR, Koch GG(1977)の基準によれば、0.41~0.60 は中程度の一致、0.61~0.80 は高度の一致、0.81~1.00 はほぼ完全な一致とされる。

サンゴ(分類)

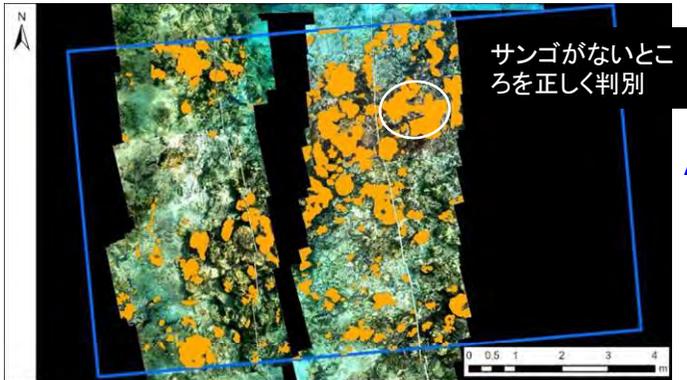
正解  
データ



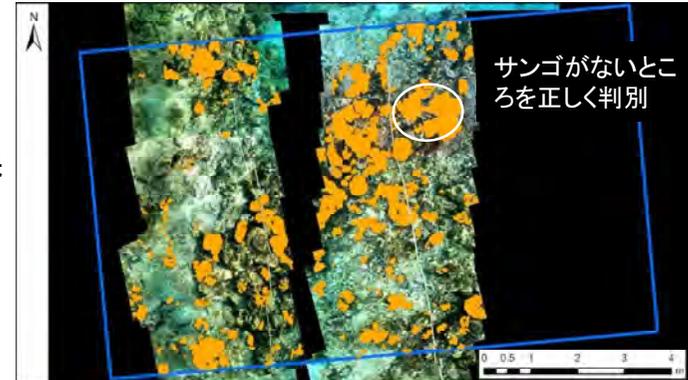
過年度  
結果



AI分類結果  
(単年)



AI分類結果  
(複数年)

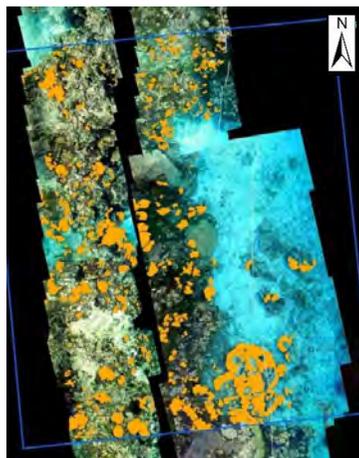


分類結果 過年度結果と比べて、サンゴがないところを正しく判別できていた。

図-IV.5.3.6 水中カメラ撮影結果のモザイク画像に対するサンゴ2分類解析結果〔2021年撮影画像：検証範囲①〕

サンゴ(分類)

正解  
データ

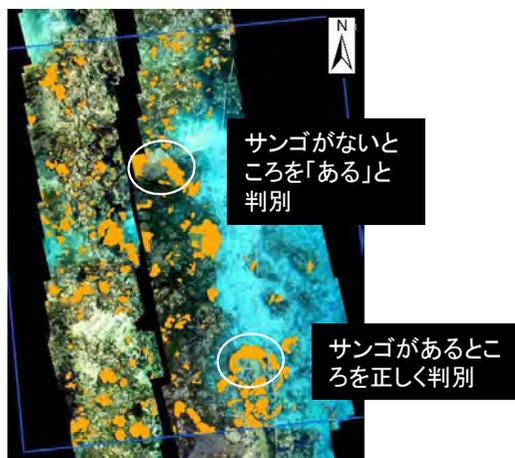


過年度  
結果



サンゴがあるところを「ない」と判別

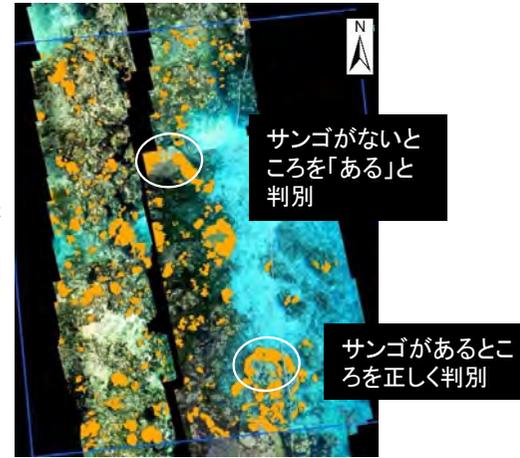
AI分類結果  
(単年)



サンゴがないところを「ある」と判別

サンゴがあるところを正しく判別

AI分類結果  
(複数年)



サンゴがないところを「ある」と判別

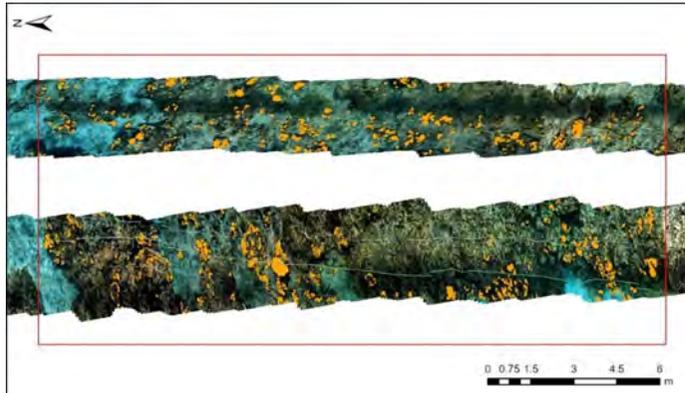
サンゴがあるところを正しく判別

分類結果 過年度結果と比べて、サンゴがあるところを正しく判別できているが、単年・複数年モデルともに、一部の場所でサンゴが無いところを「ある」と判別しているところがある。

図-IV.5.3.7 水中カメラ撮影結果のモザイク画像に対するサンゴ2分類解析結果〔2021年撮影画像：検証範囲②〕

サンゴ(分類)

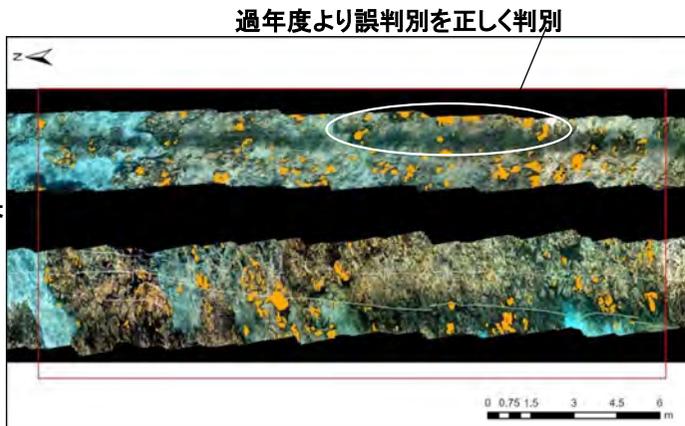
正解  
データ



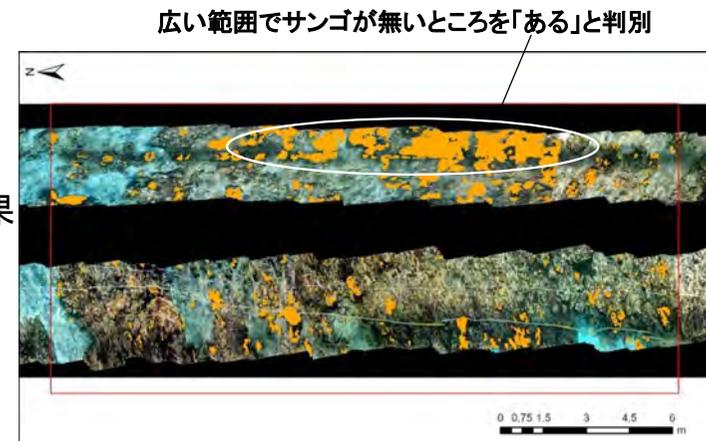
過年度  
結果



AI分類結果  
(単年)



AI分類結果  
(複数年)

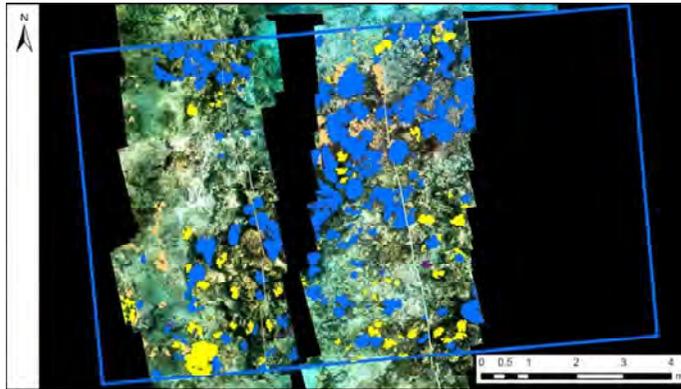


分類結果 過年度結果と比べて、単年モデルでは誤判別を正しく判別できていたが、複数年モデルでは広い範囲でサンゴがないところを「ある」と誤判別していた。

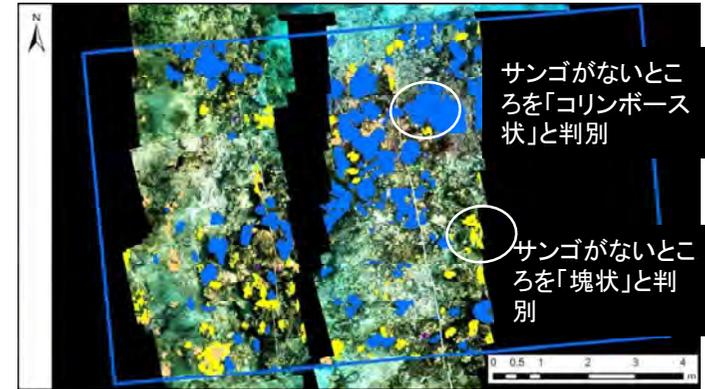
図-IV.5.3.8 水中カメラ撮影結果のモザイク画像に対するサンゴ2分類解析結果〔2022年撮影画像〕

凡例	樹枝状	コリンボース状	被覆状
	塊状	格子模様あり塊状	その他サンゴ

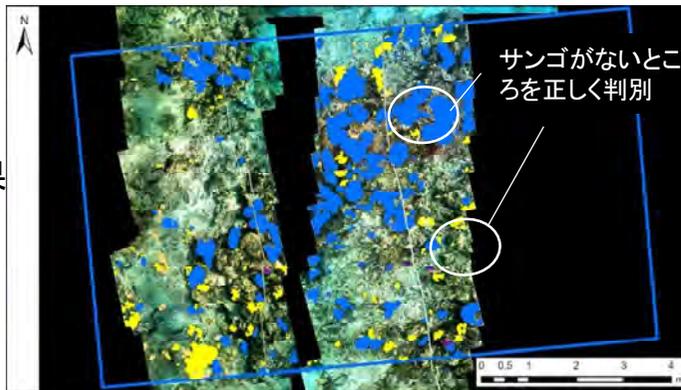
正解  
データ



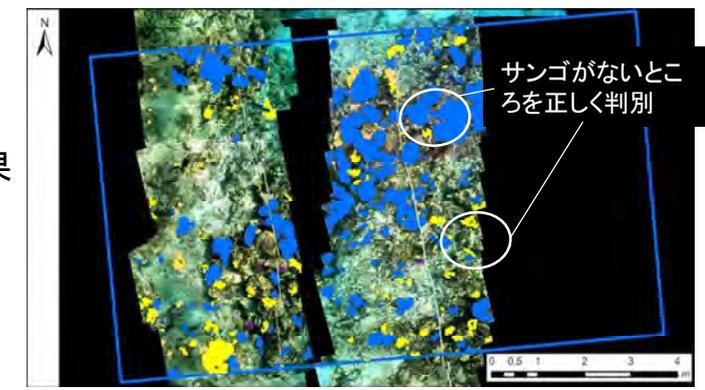
過年度  
結果



AI分類結果  
(単年)



AI分類結果  
(複数年)

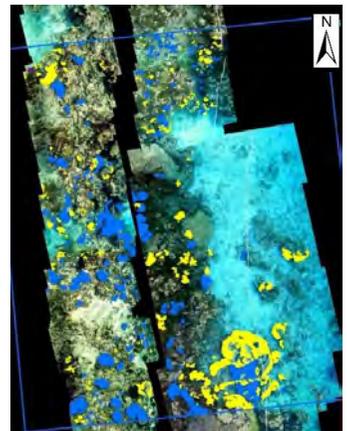


分類結果 単年、複数年モデルともに、過年度結果と比べてサンゴがないところを正しいサンゴ種に判別できていた。

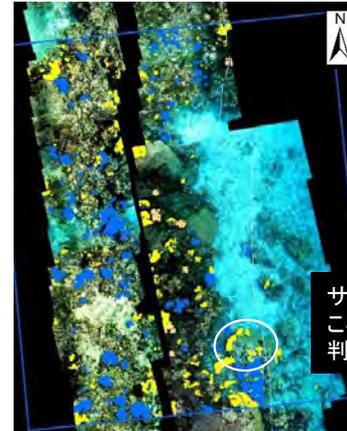
図-IV.5.3.9 水中カメラ撮影結果のモザイク画像に対するサンゴ個別分類解析結果〔2021年撮影画像：検証範囲①〕

凡例	樹枝状	コリンボース状	被覆状
	塊状	格子模様あり塊状	その他サンゴ

正解  
データ

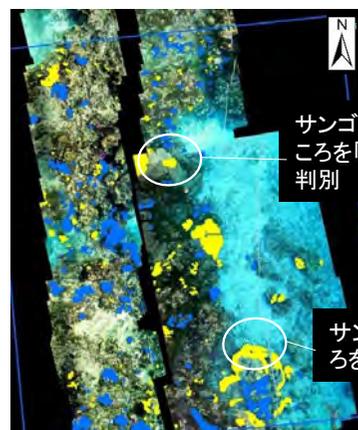


過年度  
結果



サンゴがあるところを「ない」と判別

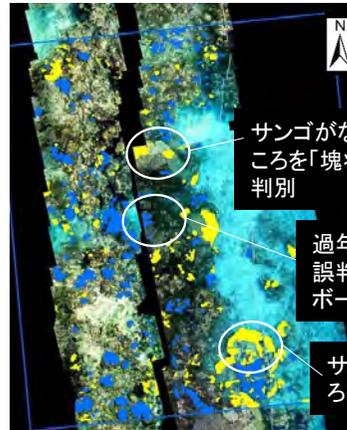
AI分類結果  
(単年)



サンゴがないところを「塊状」と判別

サンゴがあるところを正しく判別

AI分類結果  
(複数年)



サンゴがないところを「塊状」と判別

過年度及び単年度結果にて誤判別しているところを「コリンボース状」と正しく判別

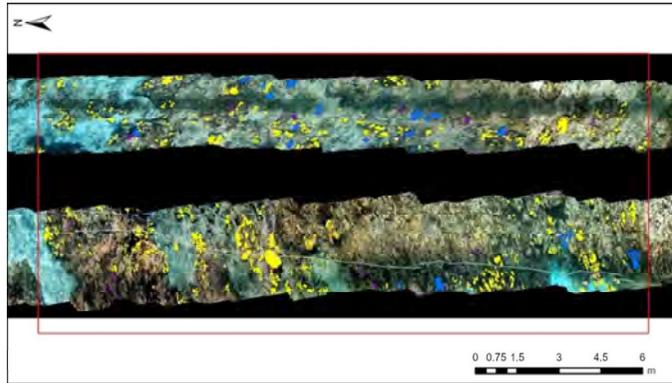
サンゴがあるところを正しく判別

分類結果 過年度結果と比べて、サンゴがあるところを正しく判別できており、過年度及び単年モデルにて誤判別していた「コリンボース状」を複数年モデルでは正しく判別できていた。

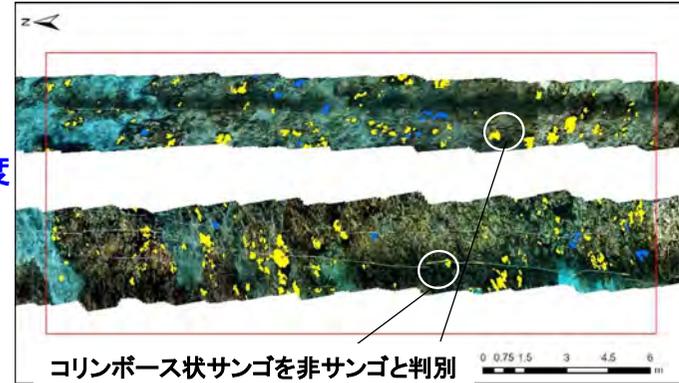
図-IV.5.3.10 水中カメラ撮影結果のモザイク画像に対するサンゴ個別分類解析結果〔2021年撮影画像：検証範囲②〕

凡例	樹枝状	コリンボース状	被覆状
	塊状	格子模様あり塊状	その他サンゴ

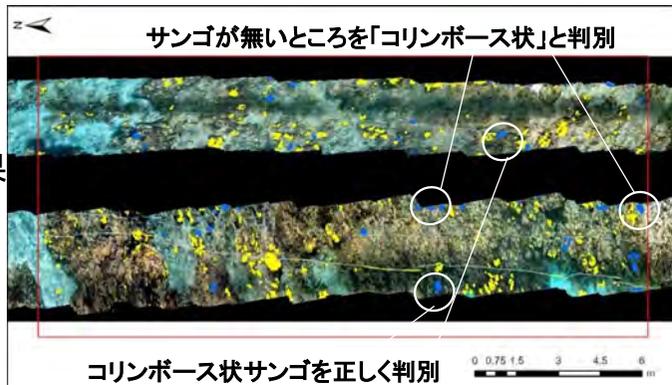
正解  
データ



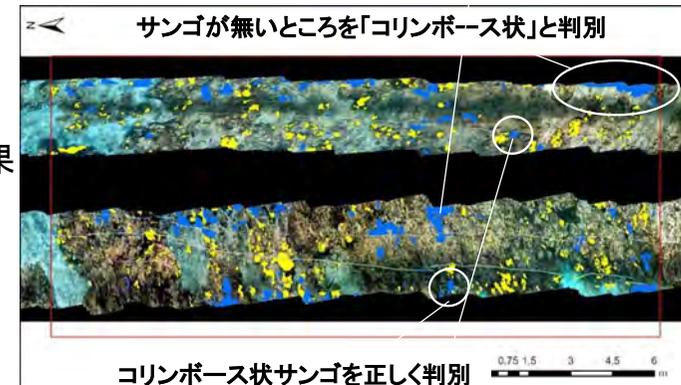
過年度  
結果



AI分類結果  
(単年)



AI分類結果  
(複数年)



分類結果 過年度結果と比べて、単年・複数年モデルともに、コリンボース状を正しく判別できている箇所があった。また、複数年モデルでは色調の明るい箇所で「非サンゴ」を「コリンボース状」と誤判別している箇所があった。

図-IV.5.3.11 水中カメラ撮影結果のモザイク画像に対するサンゴ個別分類解析結果〔2022年撮影画像〕

### 3.2 分類作業の効率化の検証

分類作業に係る作業日数について、事業計画目標の 15 日/10ha を達成できるか、沖ノ鳥島海域での分類作業の実績から検討した。

分類作業では、「モザイク画像作成」、「画像の前処理」「AI モデル構築」、「AI 解析」の手順を踏む。各工程に係る作業日数について、沖ノ鳥島海域の作業実績より算出した結果を表-IV.5.3.6 に示す。モザイク画像作成は測線長 200m あたり 9.33 時間となった。画像の前処理は測線長 200m あたり 1 時間となった。AI モデル構築は 222m<sup>2</sup> の教師データ作成には約 34 日間、作成した教師よりモデル構築にかかる日数は約 9 日間となった。AI 解析は 120m<sup>2</sup> あたり 0.024 時間となった。AI モデル構築は教師データが蓄積されモデルを構築できると、将来的には不要となる。モザイク画像の作成は撮影毎に作業が発生するため、事業目標 15 日/10ha を達成するためには、対象範囲を面的に効率的に計測、解析することが求められる。

そこで、10ha の現地計測を図-IV.5.3.12 に示すような 50m 間隔の測線を配置し計測、AI 解析することをイメージして分類作業の日数を試算した（下式を参照）。50m 間隔の測線配置を想定した場合、作業日数は 14.6 日となり事業計画目標の 15 日/10ha は達成できる。

対象範囲 10ha の分類に係る日数の試算（50m 間隔の測線配置を想定）

< 既存の AI モデルを使用する場合（モデル構築含まず） >

- ・モザイク画像作成の所要時間

解析測線長 2100m 当たり： 約 14.5 日間・・・①

- ・AI 解析の所要時間

解析面積 4200m<sup>2</sup> 当たり： 約 0.1 日間・・・②

① + ② = 約 15 日間

表-IV. 5. 3. 6 分類作業に係る作業日数（沖ノ鳥島海域の実績）

手法	対象海域	作業日数
モザイク画像の作成	沖ノ鳥島海域	解析測線長: 100m × 2測線 = 200m 測線長200m分のモザイク画像作成の所要時間: 9.33時間 1時間当たりの解析測線長: 21.4m、1日(7.5h)当たりの解析測線長: 160.5m
画像の前処理	沖ノ鳥島海域	解析測線長: 100m × 2測線 = 200m 測線長200m分の画像の前処理の所要時間: 1時間 1日(7.5h)当たりの解析測線長: 1,500m
AIモデル構築 (教師データ作成含む)	沖ノ鳥島海域	解析面積: (学習エリア37m × 3m) × 2領域 = 222m <sup>2</sup> 面積222m <sup>2</sup> 分の教師データ作成の所要日数: 約34日間 <b>AIモデル構築の所要日数: 約9日間</b>
AI解析	沖ノ鳥島海域	解析面積: (検証エリア20m × 3m) × 2領域 = 120m <sup>2</sup> 面積120m <sup>2</sup> 分のAI解析の所要時間: 0.024時間 1時間当たりの解析面積: 5,000m <sup>2</sup> 、1日(7.5h)当たりの解析面積: 37,500m <sup>2</sup>

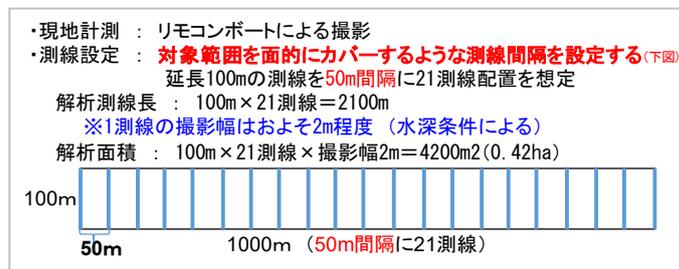


図-IV. 5. 3. 12 対象範囲 10ha の現地計測イメージ

### 3.3 考察

今年度は沖ノ鳥島海域において、AI解析による誤分類への対応策として、教師データの追加や画像の前処理を新たに行った。これら対応策の有効性について解析結果を踏まえ考察した。

#### (1) 2分類における単年と複数年モデルの分類精度評価

2021年撮影画像による単年と複数年モデルの分類精度(表-IV.5.3.7)は、ユーザー精度、プロデューサー精度ともに同程度の精度であり、単年と複数年モデルで精度の差がほとんどなく、モデルの汎用性を高めることができた。

一方、2022年撮影画像による単年と複数年モデルの分類精度(表-IV.5.3.8)では、プロデューサー精度は単年と複数年モデルで同程度となったが、「サンゴ」のユーザー精度は複数年の方が劣る結果となった。このことから、複数年の教師を学習することで、「サンゴ」を多く拾えるようになったものの、「非サンゴ」を「サンゴ」と誤判別して拾っていることが確認された。これは、2022年撮影画像は、2021年撮影画像と比べて、船の揺れの影響を受けた画像だったことが影響していると考えられた。

表-IV.5.3.7 2021年撮影画像による単年と複数年モデルの分類精度評価

2021年 単年モデル					2021+2022年 複数年モデル						
分類精度表(m)		分類結果		行方向総和	プロデューサー精度	分類精度表(m)		分類結果		行方向総和	プロデューサー精度
サンゴ	非サンゴ	サンゴ	非サンゴ			サンゴ	非サンゴ	サンゴ	非サンゴ		
照合用クラス	サンゴ	18.11	7.05	25.16	72.0%	照合用クラス	サンゴ	18.20	6.96	25.16	72.3%
	非サンゴ	4.35	129.60	133.95	96.8%		非サンゴ	4.57	129.37	133.94	96.6%
列方向総和		22.46	136.64	159.11		列方向総和		22.77	136.34	159.10	
ユーザー精度		80.6%	94.8%			ユーザー精度		79.9%	94.9%		
				全体精度	92.8%					全体精度	92.8%
				kappa係数	0.72					kappa係数	0.72

表-IV.5.3.8 2022年撮影画像による単年と複数年モデルの分類精度評価

2022年 単年モデル					2021+2022年 複数年モデル						
分類精度表(m)		分類結果		行方向総和	プロデューサー精度	分類精度表(m)		分類結果		行方向総和	プロデューサー精度
サンゴ	非サンゴ	サンゴ	非サンゴ			サンゴ	非サンゴ	サンゴ	非サンゴ		
照合用クラス	サンゴ	4.34	3.31	7.65	56.7%	照合用クラス	サンゴ	4.35	3.29	7.64	57.0%
	非サンゴ	2.95	208.43	211.38	98.6%		非サンゴ	11.07	200.27	211.34	94.8%
列方向総和		7.28	211.74	219.02		列方向総和		15.42	203.56	218.98	
ユーザー精度		59.5%	98.4%			ユーザー精度		28.2%	98.4%		
				全体精度	97.1%					全体精度	93.4%
				kappa係数	0.57					kappa係数	0.35

## (2) 個別分類における単年と複数年モデルの分類精度評価

### 1) 2021年撮影画像による単年と複数年モデルの分類精度評価

2021年撮影画像を用いた6分類の分類精度では(表-IV.5.3.9、表-IV.5.3.10)、単年より複数年モデルの方がプロデューサー精度が向上した。

ユーザー精度は、コリンボース状では単年に比べて複数年モデルの方がやや精度が低下したものの、被覆状・塊状では、複数年モデルの方が精度が向上し、全体精度やKappa係数においても、複数年モデルの方が高くなった。

そのため、教師データ数を増やすことが精度向上に寄与したと考えられた。

表-IV.5.3.9 2021年撮影画像による単年モデルの分類精度評価

分類精度表(mf)	分類結果							行方向総和	プロデューサー精度
	樹枝状(Acropora doneiなど)	コリンボース状(ハリエダストリイなど)	被覆状(コモンサゴ属など)	塊状(キカメイ属・ハマサゴ属など)	格子模様あり塊状(マルキカメイなど)	その他サゴ	非サゴ		
樹枝状(Acropora doneiなど)	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-
コリンボース状(ハリエダストリイなど)	0.00	12.20	0.00	0.01	0.00	0.00	3.39	15.60	78.2%
被覆状(コモンサゴ属など)	0.00	0.00	0.22	0.22	0.00	0.00	0.36	0.80	27.5%
塊状(キカメイ属・ハマサゴ属など)	0.00	0.01	0.03	4.45	0.02	0.00	3.34	7.85	56.7%
格子模様あり塊状(マルキカメイなど)	0.00	0.00	0.00	0.00	0.01	0.00	0.06	0.07	9.9%
その他サゴ	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-
非サゴ	0.00	1.78	0.04	2.12	0.13	0.00	130.76	134.82	97.0%
列方向総和	0.00	13.99	0.28	6.80	0.15	0.00	137.89	159.12	
ユーザー精度	-	87.2%	77.1%	65.5%	4.2%	-	94.8%		
									全体精度 92.8%
									kappa係数 0.72

表-IV.5.3.10 2021年撮影画像による複数年モデルの分類精度評価

分類精度表(mf)	分類結果							行方向総和	プロデューサー精度
	樹枝状(Acropora doneiなど)	コリンボース状(ハリエダストリイなど)	被覆状(コモンサゴ属など)	塊状(キカメイ属・ハマサゴ属など)	格子模様あり塊状(マルキカメイなど)	その他サゴ	非サゴ		
樹枝状(Acropora doneiなど)	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-
コリンボース状(ハリエダストリイなど)	0.00	13.09	0.00	0.01	0.00	0.00	2.46	15.56	84.2%
被覆状(コモンサゴ属など)	0.00	0.01	0.33	0.13	0.00	0.00	0.33	0.80	41.6%
塊状(キカメイ属・ハマサゴ属など)	0.00	0.02	0.00	5.29	0.01	0.00	2.52	7.84	67.5%
格子模様あり塊状(マルキカメイなど)	0.00	0.00	0.00	0.00	0.00	0.00	0.07	0.07	0.0%
その他サゴ	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-
非サゴ	0.00	2.29	0.05	2.19	0.07	0.00	130.22	134.83	96.6%
列方向総和	0.00	15.41	0.38	7.62	0.08	0.00	135.59	159.09	
ユーザー精度	-	85.0%	86.9%	69.4%	0.0%	-	96.0%		
									全体精度 93.6%
									kappa係数 0.76

## 2) 2022 年撮影画像による単年と複数年モデルの分類精度評価

2022 年撮影画像を用いた 6 分類の分類精度では（表-IV. 5. 3. 11、表-IV. 5. 3. 12）、単年より複数年モデルの方がプロデューサー精度が向上した。

ユーザー精度は、被服状では向上したが、コリンボース状では精度が低下し、全体精度や Kappa 係数においても、複数年モデルの方が劣る結果となった。これは、2 分類の結果と同様に、「非サンゴ」を「サンゴ」と誤判別して拾っていることが多くみられたためであり、2022 年撮影画像は、2021 年撮影画像と比べて、船の揺れの影響を受けた画像だったことが結果に影響していると考えられた。

表-IV. 5. 3. 11 2021 年撮影画像による単年モデルの分類精度評価

分類精度表(mf)	分類結果							行方向総和	プロデューサー精度
	樹枝状 (Acropora donei など)	コリンボース状 (ハリダミドリイシなど)	被覆状 (コモンサンゴ属 など)	塊状 (キカメイ属・ハマサンゴ属など)	格子模様あり塊状 (マルキカメイなど)	その他サンゴ	非サンゴ		
樹枝状 (Acropora donei など)	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-
コリンボース状 (ハリダミドリイシなど)	0.00	0.47	0.00	0.00	0.00	0.00	0.63	1.10	42.5%
被覆状 (コモンサンゴ属など)	0.00	0.00	0.01	0.08	0.00	0.00	0.17	0.27	5.4%
塊状 (キカメイ属・ハマサンゴ属など)	0.00	0.00	0.01	3.57	0.00	0.00	2.29	5.87	60.7%
格子模様あり塊状 (マルキカメイなど)	0.00	0.00	0.00	0.00	0.03	0.00	0.37	0.40	6.7%
その他サンゴ	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-	-
非サンゴ	0.00	0.88	0.07	2.18	0.02	0.00	208.20	211.35	98.5%
列方向総和	0.00	1.35	0.10	5.83	0.05	0.00	211.66	218.98	-
ユーザー精度	-	34.6%	14.8%	61.2%	50.9%	-	98.4%	-	96.9%
									kappa係数 0.54

表-IV. 5. 3. 12 2021 年撮影画像による単年モデルの分類精度評価

分類精度表(mf)	分類結果							行方向総和	プロデューサー精度
	樹枝状 (Acropora donei など)	コリンボース状 (ハリダミドリイシなど)	被覆状 (コモンサンゴ属 など)	塊状 (キカメイ属・ハマサンゴ属など)	格子模様あり塊状 (マルキカメイなど)	その他サンゴ	非サンゴ		
樹枝状 (Acropora donei など)	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-
コリンボース状 (ハリダミドリイシなど)	0.00	0.68	0.01	0.01	0.00	0.00	0.40	1.10	61.7%
被覆状 (コモンサンゴ属など)	0.00	0.00	0.05	0.07	0.00	0.00	0.14	0.27	20.3%
塊状 (キカメイ属・ハマサンゴ属など)	0.00	0.03	0.01	4.01	0.00	0.00	1.83	5.88	68.1%
格子模様あり塊状 (マルキカメイなど)	0.00	0.01	0.00	0.01	0.06	0.00	0.32	0.40	14.4%
その他サンゴ	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-	-
非サンゴ	0.00	5.83	0.11	2.68	0.02	0.00	202.90	211.34	96.0%
列方向総和	0.00	6.35	0.19	6.77	0.08	0.00	205.59	218.99	-
ユーザー精度	-	10.7%	28.6%	59.2%	70.0%	-	98.7%	-	94.8%
									kappa係数 0.45

### (3) 全体考察

- ① 単年モデルにおいて、2021年・2022年撮影画像ともに過年度よりも精度の向上がみられた。
  - ⇒ 教師データの追加及び画像の標準化は、分類精度の向上に有効である。
- ② 単年モデルよりも複数年モデルの方が、分類精度が高いサンゴ種が多い。
  - ⇒ 気象・海象状況や水深帯の異なる教師データの学習は、分類精度の向上に有効である。
- ③ 教師データ数が同程度でも、コリンボースと塊状では分類精度に違いがみられた（図-IV.5.3.13）。
  - ⇒ 塊状は形状や色が多様であることも1つの要因と考えられる。対象とするサンゴ種によって必要な教師データ数が異なることに留意して、教師データは収集する必要がある。
- ④ 2022年撮影画像よりも、2021年撮影画像を用いた検証の方が分類精度が高く、コリンボース状では事業計画目標を達成した。
  - ⇒ 2022年撮影画像は、2021年よりも船の揺れの影響を受けた画像になっており、分類精度を向上させるには、走行方向に対して横からの風がある場合は撮影は行わないなど、撮影時に海象状況を考慮することが重要である。

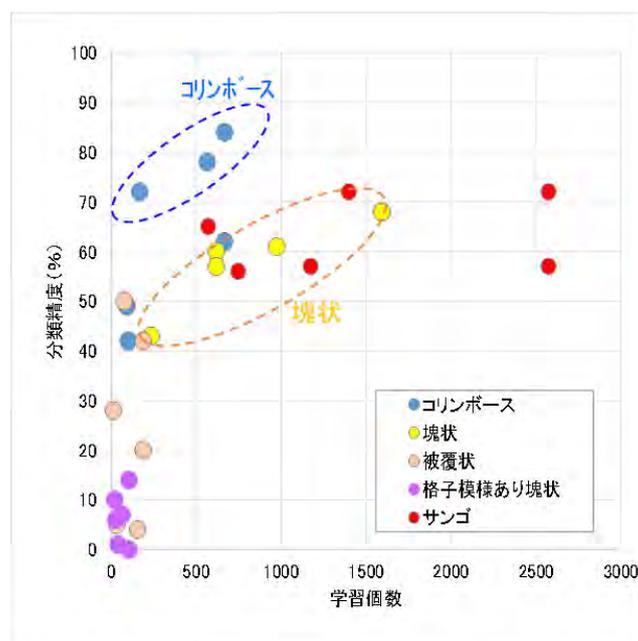


図-IV.5.3.13 教師データ数と分類精度の関係  
(過年度（単年モデル）、今年度（単年・複数年モデル）の成果より作成）

#### 4. 結果のまとめ

今年度実施したサンゴ分類の高精度化の検証の結果、教師データの追加や画像の標準化により、2021年撮影画像を用いた検証において、コリンボース状サンゴでは単年モデルで分類精度78%、複数年モデルで84%を達成し、事業計画目標の80%を達成した。

## 5. 次年度の計画（案）

### (1) 次年度の目的（案）

開発した技術の汎用化を目的として、手引きの改訂に向けて、これまでの検討結果をもとに手引きの骨子を作成するとともに、技術開発で作成した教師データを活用する方法として、自治体等のユーザーに提供する方法について検討する。

### (2) 次年度の実施項目（案）

- ・ 手引き骨子の作成（サンゴ被度計測技術）
- ・ 教師データの提供方法、データセット内容の検討

### (3) 次年度アプローチ方法（案）

- ① 教師データのデータセット（「オリジナル画像」、「ラベリング画像」等）を整理する。
- ② データセットを公表する方法（ユーザーへのデータ提供方法、データ利用に関する規定、申請書等）を検討する。
- ③ R7年度の手引き改訂に向け、骨子の作成を行う。

### (4) 次年度スケジュール（案）

4月～9月：教師データのデータセット整理、データセット公表方法の検討

10月～1月：サンゴ被度計測技術をとりまとめた手引き骨子の作成