

第 6 章 ドローンや人工衛星を活用した赤土等流出防止対策状況及び沿岸環境調査

6.1 ドローン撮影画像を用いた調査

6.1.1 調査内容

調査項目を表 6.1.1-1 に示した。

表 6.1.1-1 調査項目（ドローン撮影画像を用いた調査）

調査項目	数量	摘要
ドローン撮影	1 回	秋季を中心に撮影
画像処理	1 式	・オルソ化(歪み補正) ・DEM化(数値標高モデル) ・一筆ごとのUSLE係数付与 ・画像処理の精度向上検討
ドローン画像データと人工衛星画像との比較検証	1 式	・衛星画像購入 ・衛星画像解析

(1) 調査日

ドローン撮影

令和6年9月2日～10月18日

(2) 調査方法

1) ドローン撮影方法

ドローン撮影は、農地について、宮古島(伊良部島、池間島、多良間島含む)、西表島(黒島・波照間島含む)の約 4,000ha の範囲で静止画の撮影を行った。農地の撮影範囲については、農林水産省統計部が提供しているオープンデータである農地の区画情報(以下、筆ポリゴン)の 2022 年公開版区画を基準とし、沖縄県農林水産部や沖縄県環境保全課で過年度に行った農地の利用状況把握を目的としたドローン撮影範囲に含まれていない農地区画を撮影範囲とした。ただし、撮影困難範囲(住宅密集地(DID 地区)・防衛関連施設制限範囲(自衛隊・在日米軍)、空港周辺制限範囲)と散在農地は、撮影範囲から除外し、各地域の詳細な撮影範囲は沖縄県環境保全課と協議の上決定した。ドローンは DJI 社の Phantom4 を使用し、事前に作成したフライトプランで高度約 150m 上空より撮影を行った。



ドローン(DJI 社:Phantom4)



ドローン操縦状況

2) 筆ポリゴンの概要

筆ポリゴンの概要について図 6.1.1-1、表 6.1.1-2、表 6.1.1-3 に示す。

出典:農林水産省 HP 農地の区画情報(筆ポリゴン)について

(<https://www.maff.go.jp/j/tokei/porigon/>)(最終アクセス 2025 年 3 月 5 日)


農地の区画情報(筆ポリゴン)について

筆ポリゴンとは

- ◆ GIS(地理情報システム)ソフトウェア等において利用可能な農地の区画情報であり、農林水産省統計部が標本調査として実施する耕地面積調査等の母集団情報として整備したものを基とするデータです。



(筆ポリゴン:青色の線)



国土地理院の電子地形図に筆ポリゴンを重ね合わせたイメージ図

筆ポリゴンの作成方法・その特徴等

- ◆ 筆ポリゴンは、衛星画像等の空中写真データをGISのマップ上に表示し、目視で判読した筆ごとの形状に沿って手作業で作成しております。
- ◆ 筆ポリゴンの作成に当たっては、現地測量や現地確認を行っておらず、各種の台帳との突合等も行っておりません。このため、現況の農地、お手元の台帳等の状況とは一致しない場合があります。
- ◆ 筆ポリゴンは、大まかな農地の位置関係を示すものであり、土地の権利関係等を示すものではありません。

筆ポリゴンの利用

- ◆ 筆ポリゴンは、農林水産省WEBページにオープンデータとして公開しており、誰でも自由にご利用いただけます。なお、ご利用に当たっては、「筆ポリゴンの利用規約」を必ずご確認ください。

農地区画情報(筆ポリゴン)のデータ提供・利用: <https://www.maff.go.jp/j/tokei/porigon/index.html>

図 6.1.1-1 農地の区画情報(筆ポリゴンについて)

表 6.1.1-2 筆ポリゴンの仕様

項目	内容
測地系	日本測地系 2011 (JGD2011)
座標系	経緯度座標系
筆ポリゴン ID	UUID (汎用一意識別子) version4
ファイル形式	GeoJSON
ファイル格納データ単位	市区町村単位

表 6.1.1-3 筆ポリゴンの属性情報

属性項目名	名称	格納内容
polygon_uuid	筆ポリゴン ID	筆ポリゴン ID (UUID (汎用一意識別子) version4、32桁の英数字で構成される。) (例: 4fac03f2-2f5f-4c80-b882-911541a01fb7)
land_type	耕地の種類	田、畑の地目 (衛星画像等の目視判読による判断) 地目コード (100: 田、200: 畑)
issue_year	公開年度	筆ポリゴン公開サイトに公開した年度 (例: 2022 年度に公開したものは、「2022」)
edit_year	調製年度	筆ポリゴンを新規作成・更新 (耕地の種類の変更も含む) した年度 (例: 2021 年度に新規作成・更新作業を実施したものは、「2021」)
history	履歴	過去に公開した筆ポリゴンとの関係を示した情報 (JSON 形式で記載)。 なお、履歴の付与規則の詳細は別紙1を参照。
last_polygon_uuid	前年筆ポリゴンID	・筆ポリゴンの更新等がなく、形状が前年度公開データと全く同じポリゴン (履歴では前年同一) の場合、前年度公開データの「筆ポリゴン ID」。 ・筆ポリゴンの更新等があり、形状が前年と異なるポリゴン (履歴では発生、関連) の場合、Null 値。
prev_last_polygon_uuid	前前年筆ポリゴン ID	・最新年度の筆ポリゴンが前年度の筆ポリゴン及び前前年度の筆ポリゴンの形状と全く同じ場合、前年度の筆ポリゴンが保持していた「前年筆ポリゴン ID」。 ・最新年度の筆ポリゴンが前年度の筆ポリゴンの形状と異なる場合、Null 値。
local_government_cd	地方公共団体コード	・総務省の「全国地方公共団体コード (6 桁)」 (https://www.soumu.go.jp/denshijiti/code.html) ・筆ポリゴンの重心点が含まれる市区町村 (国土数値情報の行政区域データ) の地方公共団体コードを規則に基づき付与。
point_lng	重心点座標 (経度)	PostgreSQL の拡張モジュール PostGIS の ST_Centroid関数で計算した重心点の経度座標。 座標値は 10 進法で小数点以下9桁まで。
point_lat	重心点座標 (緯度)	PostgreSQL の拡張モジュール PostGIS の ST_Centroid関数で計算した重心点の緯度座標。 座標値は 10 進法で小数点以下9桁まで。

3) ドローン撮影地域

表 6.1.1-4 に農地の地域別撮影面積(ha)詳細を、図 6.1.1-2～図 6.1.1-3 に撮影範囲図を示した。なお、農地の面積は筆ポリゴン(2022 年公開版)より算出した。

表 6.1.1-4 陸域農地撮影面積詳細

農地面積表 概算	全農地面積(ha)	既撮影 農地面積(ha)	非撮影対象 農地面積(ha)	R6撮影 農地面積(ha)	R6ドローン 飛行面積(ha)	備考
01_沖縄島北部	5,700	3,700	2,000	0	0	
02_北部離島	2,000	500	700	0	0	
03_沖縄島中部	2,400	1,900	500	0	0	
04_沖縄島南部	3,908	2,100	1,800	0	0	
05_南部離島	2,300	0	1,200	0	0	
06_久米島	1,700	600	400	0	0	
07_宮古島	11,800	5,610	2,700	3,000	4,900	
08_石垣島	5,500	4,800	900	0	0	
09_西表島	1,800	700	100	900	1,600	
10_与那国島	500	0	300	0	0	
合計	37,608	19,910	10,600	3,900	6,500	—
		34,410				—

※宮古島(伊良部島、池間島、多良間島含む)、西表島(黒島・波照間島含む)




図 6.1.1-2 撮影範囲図(宮古島・伊良部島・池間島・多良間島)




図 6.1.1-3 撮影範囲図(西表島・黒島・波照間島)

4) 画像処理

ドローン撮影データの静止画は 5cm 程度の解像度を確保し、Agisoft 社の高解像度オルソモザイク画像作成処理ソフトウェア Metashape によりオルソ化処理を行い、位置情報が格納された GeoTIF 形式で出力し画像解析に用いた。解析は以下の項目について行い、土壌流亡予測式(USLE:Universal Soil Loss Equation)による流出量推計に必要な情報を収集した。情報収集は人工知能(AI)を用いて農地の利用状況についての調査を行い、各撮影範囲内にある筆ポリゴンの GIS データ内(属性テーブル)に付与した。

画像解析詳細は結果とともに 6.1.2(2)画像解析に示す。

【画像処理項目】

- ・オルソ化(歪み補正)
- ・DEM 化(数値標高モデル)
- ・一筆ごとの USLE 係数付与
(上記データ 3 点は HDD に格納し納品)
- ・画像処理の精度向上検討

5) 人工衛星画像購入

ドローン撮影が困難な地域に存在する農地の状況を把握するため、人工衛星画像を用いてドローン画像解析と同項目及び同精度での解析が可能か、検証を行った。

ドローン撮影画像の解像度は 5cm 程度と極めて高い解像度を有しており、この解像度により圃場における細かな栽培種情報等の収集が可能となっている。ただし、現在一般に市販されている人工衛星画像において、この解像度のものは存在しない。

一般に市販されている人工衛星画像では「World View3」が最も高解像度として知られており、これは解像度最大 30cm 程度である。以上のことから、購入画像は「World View3」の撮影画像とした。

「World View3」の仕様を表 6.1.1-5 に示した。

表 6.1.1-5 World View3の仕様

衛星名	World View 3	
解像度	最大30cm(パンシャープン)	
バンド	最大16バンド(可視5バンド、近赤外線3バンド、短波赤外線8バンド)	
	可視5バンド Coastal: 400 - 450 nm Blue: 450 - 510 nm Green: 510 - 580 nm Yellow: 585 - 625 nm Red: 630 - 690 nm 近赤外線3バンド Red Edge: 705 - 745 nm Near-IR1: 770 - 895 nm Near-IR2: 860 - 1040 nm	短波赤外線8バンド SWIR-1: 1195 - 1225 nm SWIR-2: 1550 - 1590 nm SWIR-3: 1640 - 1680 nm SWIR-4: 1710 - 1750 nm SWIR-5: 2145 - 2185 nm SWIR-6: 2185 - 2225 nm SWIR-7: 2235 - 2285 nm SWIR-8: 2295 - 2365 nm
撮影頻度	約 2 日	
その他	2014年打ち上げ	
	大気補正の有無選択、膨大なアーカイブから選択可能	

「World View3」は、2014 年に打ち上げられて以降、頻度約2日ピッチで撮影が継続されており、その膨大なアーカイブの中から購入画像を選択できる(ただし画像解析の阻害となる雲ができるだけ少ない画像を選択する必要がある)。また、画像解析の試行を行う範囲として、空港周辺等のドローン撮影困難範囲かつ、ある程度密集した農地が分布する範囲を含めるように検討し、沖縄本島南部地域で設定した。

以下に「World View3」の購入仕様を表 6.1.1-6 に示し、購入範囲図を図 6.1.1-4 に示した。

表 6.1.1-6 World View3購入仕様

衛星名	World View 3
撮影日	2022年9月21日
解像度	30cm(パンシャープン)
バンド	4バンド(可視3バンド、近赤外線1バンド)
	可視3バンド Blue: 450 - 510 nm Green: 510 - 580 nm Red: 630 - 690 nm 近赤外線1バンド Near-IR1: 770 - 895 nm
その他	大気補正有り、アーカイブ画像の購入
	ファイル形式GeoTIFF、座標系UTM/楕円形WGS84




図 6.1.1-4 World View3購入範囲図

6.1.2 ドローン撮影画像を用いた調査結果

(1) ドローン撮影

ドローン撮影を行った各地域のオルソ画像を図 6.1.2-1～図 6.1.2-2 に示す。




図 6.1.2-1 オルソ画像(宮古島・伊良部島・池間島・多良間島)




図 6.1.2-2 オルソ画像(西表島・黒島・波照間島)

(2) 画像解析

1) 解析手法

農地の利用状況について、今年度撮影した約 4,000ha の農地(筆ポリゴン 14,918 筆)を対象に人工知能(AI)による作付状況分類手法の検討を行った。

撮影したドローン画像のオルソ化後、今年度のオルソ画像の一部と、過年度のオルソ画像から目視にて 17 種別の教師データを作成。画像認識タスクにおいて高い性能を発揮する DeepLabV3 モデルを使用してピクセル分類モデルを構築し、オルソ画像内の農地筆を 17 種別に分類。1 筆あたり最も適合率の高い作物を筆ポリゴン属性データに付与した。

モデルの精度は、本島、離島から 22 サイトをテストサイトとして選択し、筆ポリゴン単位での正解率は平均 91.60%という結果を得た。

(a) 分類クラスについて

農地の利用状況は 8 種で分類しているが、実際の運用では、同じ作物でも成長度合いや種類の違いによって見た目が大きく異なる場合があり、一括りに分類してトレーニングしたところ、精度が低下することが分かった。そこで、より正確に分類するために一部の作物に対してサブクラスを設定し、その結果 AI モデルとしては 17 種を識別する形となった。最終的には、これらのサブクラスを統合することで、大元の 8 種としての識別が可能となる。

図 6.1.2-3 に分類クラスの対応図を示す。




図 6.1.2-3 大元の分類クラス8種とサブクラス17種の対応図

(b) 処理フロー

AI モデルでは最終的に 8 種を判定するが、実際には水田と不耕作地も分類する。AI モデルで推論しない理由として、水田に関しては筆ポリゴンの属性情報に「田畑」という区分があるため、そちらで判定する。不耕作地に関してはその形態が多様であり、自然のままの状態もあれば、一見すると耕作地に見えるが人の手加えられていないケースも存在する。不耕作地には明確な共通の特徴を定義しにくい側面があるため、教師データとして統一的に学習させることが難しいと判断し、学習対象としなかった。そこで、推論結果において未分類の領域が多くを占める場合や、何らかの作物を検出したとしてもその割合が低い場合、明確に分類するよりも不耕作地として扱った方が適切なケースなどを、不耕作地として分類するようにした。それを踏まえて、今回の判定処理フローを図 6.1.2-4 に示す。




図 6.1.2-4 判定処理フロー図

2) ディープラーニングワークフロー

AI 分類処理は、①教師データの作成、②ディープラーニングモデルのトレーニング、③モデル評価、④推論の実行の4つのステップで構成される。これに加えて、推論結果の分析とデータの改良を繰り返し行い、精度の向上を図った。

(a) 教師データの作成

教師データ(AI が学習するための正確なラベル付きデータセット)の作成手法として、まずオルソモザイク画像をタイル状に分割し、分類対象となる作物をポリゴンで囲み、ラベル付けをする作業を繰り返し行い、データセットを構築した。画像に対してのラベル付け(アノテーション)作業は、アノテーションツール「labelme」を使用した。

ラベル付け作業の様子を図 6.1.2-5 に示す。




図 6.1.2-5 ラベル付け作業状況

今回の学習では、合計 4,762 枚のデータセットを使用し、教師データとして 70%、検証データとして 30%の割合で分割した。各クラスのデータ枚数を表 6.1.2-1 に示す。

表 6.1.2-1 各クラスのデータセット枚数

作物区分	データ枚数
サトウキビ	1,194
若いサトウキビ	302
パインアップル	471
若いパインアップル	179
防鳥ネットパイン	182
バナナ	465
樹冠のある果樹	155
電照菊	218
観葉植物	273
牧草	510
野菜	414
骨組みハウス野菜	419
マルチング野菜	421
裸地	646
ビニールハウス	901
壊れたハウス	168
被覆野菜	280

ここで、今回のデータセットは合計 4,762 枚の画像で構成されているが、クラスごとのデータ枚数を合計すると、7,198 枚となる。これは、1 枚の画像内に複数のクラスが存在する場合、それぞれを個別にカウントしているためである。例えば、1 枚の画像内に、「サトウキビ」「牧草」「裸地」「野菜」が含まれていた場合、それぞれ 1 枚としてカウントするため、実際の画像枚数は 1 枚でも、クラス別のカウントでは 4 枚と計上されることになる。また、1 枚の画像内に同じクラスのオブジェクトが複数含まれていても、1 つとしてカウントしている。例えば、画像内に「牧草、牧草、牧草、サトウキビ」が分布している場合でも、牧草 1 枚、サトウキビ 1 枚として計上している。

今回の AI モデルで分類する 17 種の教師データサンプルを図 6.1.2-6 に示す。



サトウキビ



若いサトウキビ



パイナップル



若いパイナップル




防鳥ネットパイン



バナナ



樹冠のある果樹



電照菊



観葉植物




牧草



野菜



骨組みハウス野菜



マルチング野菜




裸地



ビニールハウス



壊れたハウス



被覆野菜

図 6.1.2-6 17種教師データサンプル

(b) ディープラーニングモデルのトレーニング

アノテーションツール「labelme」を使用し作成した教師データを、セマンティックセグメンテーション(画像の各ピクセルを特定のカテゴリに分類するタスク)に特化したディープラーニングモデル「DeeplabV3」を使用し、過年度までの学習データも用いて、再トレーニングをするファインチューニングを行った。トレーニングには Google Colab Pro+ を使用し、高スペックな GPU 環境を活用することで、大規模なデータセットでも効率的に学習できるようにした。

バックボーンモデルは RESNET-101、最大エポック数は 100、バッチサイズ 16 というパラメータでトレーニングを行った。また過学習の防止や計算コスト削減のため、アーリーストップリング(Early Stopping)を実装し、20 エポック連続で精度が改善しなかった場合はトレーニングを停止するようにした。

トレーニングでは、「DeepLabV3」を用いて 100 パターン程度のモデルを作成し、その中から精度の良い上位 3 つのモデル(A モデル、B モデル、C モデル)を選定した。3 つのうち C モデルが最も高い精度を示したものの、A モデルや B モデルには C モデルにはない特徴がみられたため、これらの情報を活かす方法として重み付きアンサンブルアプローチを行った。

具体的には、各モデルが画像を解析する際、それぞれが「どのクラスに属するか」を確率で出力する。この確率に対して、過去の検証結果から得られた「信頼度の重み」をかけることで、各モデルの予測に差をつけるようにしている。

例えば、あるモデルが「このピクセルはサトウキビの確率が 80%」と判断した場合、そのモデルがこれまでサトウキビを正しく分類できていた割合を参考にし、信頼度の高い予測ほど影響を強くするようにした。こうして 3 つのモデルの出力を統合し、最終的に最も確率の高いクラスを予測結果としている。この方法により、単体のモデルでは上手く分類できなかったケースでも、各モデルの強みを組み合わせることで、より精度の高い結果を得ることができた。

(c) モデル評価

モデルの性能を評価するため、また、地域ごとに精度のバラつきがないかを検証できるよう、22 の評価サイトを設定した。具体的には、本島北部に 5 エリア、本島中部に 6 エリア、本島南部に 3 エリア、宮古島に 3 エリア、石垣島に 3 エリア、久米島と多良間島にそれぞれ 1 エリアずつ設けた。

評価方法としては、まず筆ポリゴンごとに目視で正解データを付与し、その上でモデルの推論結果をもとに最適なクラスを決定。最終的にその結果の正誤を集計し、筆ポリゴン単位での正答率を算出することでモデルの精度を評価した。

22 のテストサイトに対する評価結果を表 6.1.2-2 に示す。

評価の結果、A モデルで平均 86.57%(77.85~96.12%)、B モデルで 89.20%(78.94~98.88%)、C モデルで 89.87%(73.85~97.77%)となり、アンサンブルアプローチモデルでは、平均 91.60%(80.0~98.90%)となった。

上位 3 モデルおよびアンサンブルアプローチの精度評価結果を踏まえ、最終モデルとして、精度の平均値が最も高かったアンサンブルアプローチモデルを採用した。

これは全体としての安定性と、平均的な精度向上を重視した結果である。


また、各エリアごとに精度の高いモデルを選択して運用する方法も検討したが、エリア境界の設定に伴う予期せぬ精度低下や矛盾が発生する可能性があることから、採用は見送った。

表 6.1.2-2 モデル評価結果

サイト	A モデル(%)	B モデル(%)	C モデル(%)	アンサンブル(%)
国頭村	83.53	88.41	87.19	92.68
東村①	77.85	82.55	80.53	82.55
東村②	92.70	95.83	97.39	98.43
今帰仁村	88.52	95.08	96.17	98.90
恩納村	90.19	88.23	90.19	90.19
読谷村	92.87	90.47	95.23	97.61
うるま市	84.25	85.03	88.18	88.97
沖縄市	80.76	87.17	88.46	89.74
北中城村	80.83	79.77	83.33	85.83
中城村	80.76	83.76	82.05	88.03
西原町	80.00	80	84.44	80.00
南城市	87.67	91.09	93.83	93.15
八重瀬町	86.66	98.88	97.77	97.77
糸満市	84.09	86.68	90.9	91.55
宮古島①	95.50	95.27	96.21	96.69
宮古島②	89.31	94.44	91.45	94.87
宮古島③	96.12	97.67	97.67	97.67
石垣島①	84.02	95.26	87.57	94.08
石垣島②	93.22	88.13	92.37	93.22
石垣島③	81.01	84.81	87.34	86.07
久米島	80.30	78.94	73.85	82.17
多良間島	94.47	94.93	94.93	94.93
平均値	86.57	89.20	89.87	91.60

このアンサンブルアプローチを用いた分類結果を、作物区分ごとに図 6.1.2-7～図 6.1.2-11 に示し、農地の分類結果は糸満市と宮古島の一部農地を抜粋し図 6.1.2-12、図 6.1.2-13 に示した。


サトウキビの例



若いサトウキビの例



パイナップルの例



若いパイナップルの例



図 6.1.2-7 アンサンブルアプローチ分類結果(1)

バナナの例



樹冠のある果樹の例



電照菊の例




図 6.1.2-8 アンサンブルアプローチ分類結果(2)

観葉植物の例



牧草の例



野菜の例





骨組みハウス野菜の例



図 6.1.2-9 アンサンブルアプローチ分類結果(3)

マルチング野菜の例



被覆野菜の例



裸地の例



ビニールハウスの例




図 6.1.2-10 アンサンブルアプローチ分類結果(4)

壊れたハウスの例



図 6.1.2-11 アンサンブルアプローチ分類結果(5)



図 6.1.2-12 アンサンブルアプローチ分類結果抜粋(糸満市)



図 6.1.2-13 アンサンブルアプローチ分類結果抜粋(宮古島)

さらに今回の AI モデルの分類性能を評価するための指標の一つである、混同行列 (Confusion Matrix) を図 6.1.2-14、図 6.1.2-15 に示す。これは各クラスがどの程度正しく分類されているか、またどのクラスと誤分類されやすいかを視覚的に表したものである。行が「実際のクラス(正解データ)」、列が「モデルの予測クラス」を示し、対角成分の値が高いほど正しく分類されていることを意味する。今回の結果では、図 6.1.2-14 で示す AI クラス 18 種混合行列が、AI モデルが推論した 18 の細かい分類結果を示しており、図 6.1.2-15 で示す大元のクラス 9 種混合行列は、これらの細かいクラスを統合した大元の分類結果を示している。この 2 つの混同行列を比較することで、AI が細かい分類を行う際の精度と、大きなカテゴリ単位での精度の違いを確認できる。

大元の分類クラスでの混同行列から分類精度を確認すると、前述したとおり、対角成分の値が高いほど正しく分類されていることを意味し、今回の結果では「サトウキビ」「果樹」「パイナップル」「ビニールハウス」「裸地」「牧草」などのクラスで特に高い精度を示している。これらのクラスは 90% 以上の正答率を記録しており、モデルが安定して正しく分類できていることが分かる。一方で、「花卉」「野菜」のクラスでは他のクラスと比べて精度がやや低下しており、特に「野菜」のクラスは 75% の正答率にとどまっている。

「野菜」については、種類が豊富であることから 4 つのサブクラスを設け、それぞれ分散させて学習を行ったが、それでも学習データのバリエーションが不足しており、モデルが十分に識別できるまでには至らなかったと考えられる。野菜は生育段階や栽培環境によって見た目が大きく変化するため、サブクラスの再検討や、さらなるデータの充実が必要である。




図 6.1.2-14 AIクラス18種混合行列




図 6.1.2-15 大元のクラス9種混合行列

(d) 推論の実行

AI 分類による 9 種の作物区分に水田を加えた 10 種の作物区分分類結果を、今年度のドローン撮影対象の筆ポリゴンに反映させた結果を図 6.1.2-16～図 6.1.2-29 に示す。






図 6.1.2-16 全撮影範囲画像と作物分類結果(宮古島1エリア)



凡例

サトウキビ	果樹	牧草	裸地	ビニールハウス	水田	不耕作地
パインアップル	花卉	野菜				

図 6.1.2-17 全撮影範囲画像と作物分類結果(宮古島2エリア)



凡例

サトウキビ	果樹	牧草	裸地	ビニールハウス	水田	不耕作地
パインアップル	花卉	野菜				

図 6.1.2-18 全撮影範囲画像と作物分類結果(宮古島3エリア)




図 6.1.2-19 全撮影範囲画像と作物分類結果(宮古島4エリア)




図 6.1.2-20 全撮影範囲画像と作物分類結果(宮古島5エリア)




図 6.1.2-21 全撮影範囲画像と作物分類結果(宮古島6エリア)



凡例

サトウキビ	果樹	牧草	裸地	ビニールハウス	水田	不耕作地
パインアップル	花卉	野菜				

図 6.1.2-22 全撮影範囲画像と作物分類結果(池間島エリア)




図 6.1.2-23 全撮影範囲画像と作物分類結果(伊良部島エリア)




図 6.1.2-24 全撮影範囲画像と作物分類結果(多良間島エリア)



凡例

サトウキビ	果樹	牧草	裸地	ビニールハウス	水田	不耕作地
パインアップル	花卉	野菜				

図 6.1.2-25 全撮影範囲画像と作物分類結果(黒島エリア)




図 6.1.2-26 全撮影範囲画像と作物分類結果(西表島1エリア)




図 6.1.2-27 全撮影範囲画像と作物分類結果(西表島2エリア)




図 6.1.2-28 全撮影範囲画像と作物分類結果(西表島3エリア)



凡例

サトウキビ	果樹	牧草	裸地	ビニールハウス	水田	不耕作地
パインアップル	花卉	野菜				

図 6.1.2-29 全撮影範囲画像と作物分類結果(波照間島エリア)

6.1.3 ドローン画像データと人工衛星画像との比較検証

(1) 人工衛星画像購入

購入した「World View3」の撮影画像を図 6.1.3-1 に示す。

撮影範囲は前述の通り、空港周辺等のドローン撮影困難範囲かつ、ある程度密集した農地が分布する範囲を含めるように検討し、沖縄本島南部地域の 10,000ha の範囲とした。



図 6.1.3-1 World View3撮影画像

(2) ドローン画像と人工衛星画像との比較検証

1) 解析手法

農地の利用状況を把握するため、衛星画像を対象に人工知能(AI)による作付状況分類手法の検討を行った。解析には、大気補正(ACOMP)を適用した World View3 衛星画像を使用した。

トレーニングデータの作成方法として、①衛星画像から直接トレーニングデータを作成しモデルトレーニングを行うパターン、②ドローンオルソ画像からトレーニングデータを作成し、最終的に衛星画像を用いたトレーニングデータでファインチューニングを行うパターンの2種類を試行した。いずれの手法においても、ドローンオルソ画像の解析にも用いたディープラーニングモデル「DeeplabV3」を使用した。

分類クラスの設定にあたっては、衛星画像はドローンオルソ画像に比べて解像度が低く、細かな対象の識別が難しいことを考慮し、クラス数を削減した。最終的に、判別可能な作物として7種を設定した。この選定理由は、人間が目視で判定できる種類がこれらに限られたためである。なお、パインなど一部の作物については、今回使用した衛星画像の対象範囲が南部エリアに限定されていたことから、分析対象から除外した。

モデルの精度は、南城市、八重瀬町、糸満市から1サイトずつ、計3サイトをテストサイトとして選択し、筆ポリゴン単位での正解率は①の衛星画像からトレーニングデータを作成した手法で平均76.45%、②のドローンオルソ画像でトレーニングしファインチューニングを行った手法で平均65.19%となった。

(a) 分類クラスについて

今回分類するクラスは以下のとおりである。前述したとおり、解像度の問題から成長度合いの違いによるサブクラスの設定は行わなかった。ただし、マルチング野菜に関しては衛星画像からもその特徴をはっきり確認できたため、分類クラスに設定した。また、花卉についても電照菊のみを対象とした。

- ・サトウキビ
- ・牧草
- ・野菜
- ・裸地
- ・ビニールハウス
- ・マルチング野菜
- ・電照菊

2) ディープラーニングワークフロー

今回の AI 分類処理は、①教師データの作成、②ディープラーニングモデルのトレーニング、③モデル評価で構成し、今後の改善点の洗い出しを行った。

(a) 教師データの作成

アノテーションツール「labelme」を使用して、分類対象となる作物をポリゴンで囲み、教師データを作成し、今回の学習では、衛星画像から作成したトレーニングデータが合計 559 枚で、ドローンオルソ画像から作成したトレーニングデータが 441 枚とした。各クラスのデータ枚数を表 6.1.3-1、表 6.1.3-2 に示す。

表 6.1.3-1 衛星画像での各クラスのデータセット枚数

作物区分	データ枚数
サトウキビ	315
牧草	185
野菜	73
裸地	378
ビニールハウス	283
マルチング野菜	12
電照菊	71

表 6.1.3-2 ドローンオルソ画像での各クラスのデータセット枚数

作物区分	データ枚数
サトウキビ	307
牧草	191
野菜	52
裸地	177
ビニールハウス	138
マルチング野菜	34
電照菊	52

画像枚数のカウントについては、前述のドローンオルソ画像解析時と同様である。今回 AI モデルで分類する 7 種の教師データのサンプル例を図 6.1.3-2 に示す。



サトウキビ



牧草



野菜



裸地



ビニールハウス



マルチング野菜



電照菊

図 6.1.3-2 7種教師データサンプル

(b) ディープラーニングのトレーニング

アノテーションツール「labelme」を使用し作成した教師データを、ディープラーニングモデル「DeeplabV3」を使用し、トレーニングを行った。トレーニングには Google Colab Pro+ を使用し、高スペックな GPU 環境を活用することで、大規模なデータセットでも効率的に学習できるようにした。

バックボーンモデルは RESNET-101、最大エポック数は 100、バッチサイズ 16 というパラメータでトレーニングを行った。

トレーニングは、①衛星画像から直接トレーニングデータを作成し、モデルトレーニングを行う手法と、②ドローンオルソ画像からトレーニングデータを作成し、最終的に衛星画像を用いたトレーニングデータでファインチューニングを行う手法の 2 種類を試行した。

①の手法については、ドローンオルソ画像解析時と基本的な流れは同様で、データが衛星画像のデータに変わっただけであるため詳細は割愛する。

②の手法では、ドローンオルソ画像を用いてトレーニングデータを作成し、最終的に衛星画像を用いたトレーニングデータでファインチューニングを行うものである。実施の目的は、ドローンオルソ画像を衛星画像の推論にも活用できるか、またその際に十分な精度を確保できるかを検証することである。

今回使用する衛星画像は大気補正が施されているため、ドローンオルソ画像のデータも適用可能であると考えた。大気補正により、画像データの輝度値が補正されるため、ドローンオルソ画像と衛星画像のデータを組み合わせた解析が可能となる。しかし、両者の解像度やスペクトル特性は異なるため、ドローンオルソ画像のトレーニングデータをそのまま適用すると精度が低下する可能性がある。

そこで、まず前処理として、ドローンオルソ画像のトレーニングデータを衛星画像の解像度に合わせるためのダウンサンプリングを実施した。次に、衛星画像のクラスごとのデータ分布を解析し、バンドごとの値のヒストグラムを取得した。これを基準として、データ分布を調整(ヒストグラムマッチング)し、衛星画像のスケールに適合させた。この工程により異なるセンサー間で生じる輝度値の違いを補正し、データの統一性を確保した。

この補正したデータを用いてモデルのトレーニングを行い、その後衛星画像のトレーニングデータを使用してファインチューニングを実施した。

(a) モデル評価

モデルの性能を評価するため、3つの評価サイト(南城市、八重瀬町、糸満市)を設定した。また今回は、①衛星画像から直接トレーニングデータを作成し、モデルトレーニングを行う手法と、②ドローンオルソ画像を用いてトレーニングデータを作成し、最終的に衛星画像を用いたトレーニングデータでファインチューニングを行う手法の2種類を施行したが、比較のためドローンオルソ画像のみを用いてトレーニングしたモデルの評価も行い、最終的に3つのモデルの精度を検証した。

評価方法としては、まず筆ポリゴンごとに目視で正解データを付与し、その上でモデルの推論結果をもとに最適なクラスを決定。最終的にその結果の正誤を集計し、筆ポリゴン単位での正答率を算出することでモデルの精度を評価した。評価結果を表 6.1.3-3 に示す。3つの学習パターンを比較した結果、衛星画像のみでトレーニングを行ったモデルが最も高い精度を示した。

衛星画像のみでトレーニングを行ったモデルの精度が 72.64～79.53%と最も高かった理由について、センサー間のデータ特性の違いが大きな要因だと考えられる。ドローンオルソ画像と衛星画像では、解像度、視野、スペクトル特性が大きく異なるため、事前処理としてドローンオルソ画像のダウンサンプリングやヒストグラムマッチングを行ったが、それだけでは両者の違いを完全に補正することは不十分であったと考えられる。またファインチューニングに関しても、初期学習の段階で適切な特徴を捉えられず、うまく補正しきれなかった可能性がある。衛星画像のみでのトレーニングでは、最初から適切な特徴を学習できるため、結果として最も精度が高くなった。

この結果から、ドローンオルソ画像を活用する際には、単純なヒストグラムマッチングやダウンサンプリングだけではなく、より高度なスペクトル変換やドメイン適応技術(異なるデータ分布(ドメイン)を持つデータ間で学習したモデルを適応させる技術)の導入が必要である。今後の改善点として、ドローンと衛星のスペクトル特性をより統合する方法の検討や、データ拡張を用いた適応的な学習手法の導入が課題となる。

表 6.1.3-3 3つの学習パターンでのモデル評価結果

サイト	衛星画像のみ(%)	ドローン画像+衛星(%)	ドローン画像のみ(%)
南城市	77.20	67.40	64.21
八重瀬町	79.53	67.18	61.00
糸満市	72.64	60.98	55.60

衛星画像のみでトレーニングを行ったモデルと、ドローンオルソ画像でトレーニングし、衛星画像でファインチューニングを行ったモデルの分類結果を、それぞれ 3 サイトの一部農地を抜粋し図 6.1.3-3～図 6.1.3-8 に示す。また、それぞれの混同行列(Confusion Matrix)を図 6.1.3-9、図 6.1.3-10 に示す。



AI による分類




図 6.1.3-3 衛星画像のみでトレーニングしたモデルの分類結果抜粋(南城市)




図 6.1.3-4 ファインチューニングしたモデルの分類結果抜粋(南城市)



図 6.1.3-5 衛星画像のみでトレーニングしたモデルの分類結果抜粋(八重瀬町)



AI による分類




図 6.1.3-6 ファインチューニングしたモデルの分類結果抜粋(八重瀬町)



AI による分類



図 6.1.3-7 衛星画像のみでトレーニングしたモデルの分類結果抜粋(糸満市)



AI による分類



図 6.1.3-8 ファインチューニングしたモデルの分類結果抜粋(糸満市)




図 6.1.3-9 衛星画像のみでトレーニングしたモデルの混同行列




図 6.1.3-10 ファインチューニングしたモデルの混同行列

6.1.4 次年度以降の調査内容提言

(1) 計画の進捗

ドローン撮影画像による全県的農地撮影計画の進捗として、表 6.1.4-1 に撮影進捗表(概算)を示す。

表 6.1.4-1 撮影進捗表(概算)

農地面積表 概算	全農地面積(ha)	既撮影 農地面積(ha)	非撮影対象 農地面積(ha)	未撮影 農地面積(ha)	未ドローン 飛行面積(ha)	備考
01_沖縄島北部	5,700	3,700	2,000	0	0	
02_北部離島	2,000	500	1,500	550	1,000	
03_沖縄島中部	2,400	1,900	500	30	70	津堅島のみ
04_沖縄島南部	3,908	2,100	1,800	8	30	久高島のみ
05_南部離島	2,300	0	1,200	1,050	1,800	
06_久米島	1,700	600	400	620	1,400	
07_宮古島	11,800	8,610	2,700	260	500	
08_石垣島	5,500	4,800	900	0	0	
09_西表島	1,800	1,640	100	0	0	
10_与那国島	500	0	300	190	350	
合計	37,608	23,850	11,400	2,708	5,150	—
		37,958				—

※全農地面積は、2022 年公開版の筆ポリゴンデータより算出した。

※既撮影農地は、農林部局と環境保全課でこれまでに実施したドローン撮影範囲。(令和4年度に営農支援課において実施した、名護市の詳細な撮影範囲は不明のため名護市全域を既撮とした)

※非撮影対象農地とした範囲は、以下の事由による。

- ・住宅密集地(DID 地区)
- ・防衛関連施設制限範囲(自衛隊・在日米軍)
- ・空港周辺制限範囲
- ・散在農地

※未撮影農地は、全農地から既撮影農地と非撮影対象農地を除いた農地。

※未ドローン飛行面積は、未撮影農地を撮影する際に必要な農地以外の部分も含めたドローン飛行面積。

(2) 追加撮影の提案

今年度までの撮影計画として、農林部局で過年度に実施した撮影範囲については既撮影範囲として計画からは除外していたが、画像確認を行ったところ、画像解析による農地の利用状況調査に適していないことが確認されたので、この撮影範囲について再撮影することを提案する。画像解析調査に適していない理由を以下に述べる。

1) 撮影時期について


農林部局で実施したドローン撮影画像は、1～2月に撮影されたものが多い。

環境保全課で実施している9月～11月頃までの撮影画像を用いてAIによる画像解析を行っているため、栽培種判定が困難となる可能性がある。

・2020年2月2日撮影 石垣島のサトウキビ畑



・撮影時期抜粋



・AI による画像解析の試行

・オルソ画像

・AI 解析結果



収穫後のサトウキビをほとんど検出できていない。

2) 撮影時間帯について

撮影された時間帯が日の入り直前のものがあるため、夕日の影響で写真全体に赤みがかかりAIによる画像解析に影響を与える可能性がある。

・2020/1/21 17:30 撮影




・2020/1/22 11:44 撮影



・撮影時刻抜粋(久米島)

- ✓ 8時～
- ✓ 9時～
- ✓ 10時～
- ✓ 11時～
- ✓ 12時～
- ✓ 13時～
- ✓ 14時～
- ✓ 15時～
- ✓ 16時～
- ✓ 17時～
- ✓ 18時～




・AI による画像解析の試行

石垣 (2020/02/02撮影)



収穫後、刈り残し後のサトウキビ。



収穫後の土地は裸地、中央の刈り残しサトウキビはサトウキビと検出している。

石垣 (2020/02/02撮影)



収穫後、刈り残し後のサトウキビ。



収穫後の土地は裸地、中央の刈り残しサトウキビはサトウキビと検出している。
一部観葉植物と検出してしまっている。

3) ぼやけた写真がある

オルソ画像作成の際の設定の影響かぼやけた状態の画像があり、AI による画像解析に影響を与える可能性がある。

・2019 年撮影オルソ画像



・環境保全課業務でのオルソ画像



・AI による画像解析の試行

久米島（2020/01/21撮影）



サトウキビ。オルソ画像がぶれてしまっている。

サトウキビ



オルソの品質に起因して、一部サトウキビ検出ができていない。

久米島（2020/01/21撮影）



サトウキビ。オルソ画像がぶれてしまっている。

サトウキビ






オルソの品質に起因して、大部分のサトウキビ検出ができていない。



4) AI による画像解析の試行まとめ

農林部局撮影画像から本島本部町、石垣島、久米島に試行サイトを設け、AI 判定正答率(筆ポリゴン単位)を算出した。

・農林部局撮影画像の試行サイト別正答率



- ・「本業務成果での正答率」と「農林部局撮影画像に対する正答率」との比較



- ・「ハウス」ではほとんど正答率に差がないものの、その他の項目では低正答率のケースが含まれる。
- ・農林画像 3 サイトでの正答率の差異は、前述 3 課題の発生頻度の差異に基づくものと考えられる。

以上のことから、農林部局で撮影した範囲はすべて再撮影したほうがよいと考えられる。

本業務上重要である「重点監視地域」がすべて上記農林部局撮影範囲に含まれており、従って「重点監視地域」が他の流域と比べ流出量の推定精度が低くなってしまうという事が問題として想定されるためである。

再撮影を実施するとした場合の数量について表 6.1.4-2 に示す。また、再撮影範囲を含めた撮影進捗図を図 6.1.4-1～図 6.1.4-10 に示す。

表 6.1.4-2 撮影進捗表(再撮影範囲含む概算)

農地面積表 概算	全農地面積(ha)	(A) 既撮影 農地面積(ha)	(B) 非撮影対象 農地面積(ha)	(C) 未撮影 農地面積(ha)	(D) 再撮影 農地面積(ha)	未ドローン 飛行面積(ha)	再ドローン 飛行面積(ha)	備考
01_沖縄島北部	5,700	3,700	2,000	0	2,800	0	8,000	
02_北部離島	2,000	500	1,500	550	0	1,000	0	
03_沖縄島中部	2,400	1,900	500	30	0	70	0	津堅島のみ
04_沖縄島南部	3,908	2,100	1,800	8	90	30	170	久高島のみ
05_南部離島	2,300	0	1,200	1,050	0	1,800	0	
06_久米島	1,700	600	400	620	650	1,400	1,400	
07_宮古島	11,800	8,610	2,700	260	0	500	0	
08_石垣島	5,500	4,800	900	0	2,900	0	5,200	
09_西表島	1,800	1,640	100	0	750	0	1,500	
10_与那国島	500	0	300	190	0	350	0	
合計	37,608	23,850	11,400	2,708	7,190	5,150	16,270	—
		A+B+C= 37,958		C+D= 9,898				




図 6.1.4-1 撮影進捗図 01_沖縄島北部



図 6.1.4-2 撮影進捗図 02_北部離島




図 6.1.4-3 撮影進捗図 03_沖縄島中部




図 6.1.4-4 撮影進捗図 04_沖縄島南部




図 6.1.4-5 撮影進捗図 05_南部離島(座間味島、渡嘉敷島、栗国島、渡名喜島、北大東島、南大東島)




図 6.1.4-6 撮影進捗図 06_久米島




図 6.1.4-7 撮影進捗図 07_宮古島(多良間島含む)




図 6.1.4-8 撮影進捗図 08_石垣島



図 6.1.4-9 撮影進捗図 09_西表島(黒島、波照間島含む)




図 6.1.4-10 撮影進捗図 10_与那国島

(3) ドローン画像と人工衛星画像との比較検証について

本業務で試行した、衛星画像(WorldView3)を対象とした AI による画像解析の正解率は平均 76.45%であり、ドローン画像を対象とした正解率(93.3%)と比べると精度は落ちたものの、一定程度の精度は確保できることが確認できた。より精度を上げる手法として、まずはトレーニングデータを増やすことが挙げられる。今回解析を行った沖縄島南部エリアだけではなく、例えば中北部エリアを追加し、植生クラスも多様性が出るようデータを増やしてモデルのトレーニングを行うこと。また、衛星画像は近赤外線バンド値も含んでいることから、植生指数(NDVI)を用いた作物ごとの特性を捉えモデルに組込めるかの試行を行い、更に今回使用した「DeepLabV3」以外のモデルでも試行する事で、解析精度向上を図ることができると考えられる。これらのことを踏まえ、次年度以降、全県的にドローン撮影不可範囲の worldview3 を購入し、AI 作物判定を行うことを提案する。ただし、AI 分類モデルは、追加購入予定分も含め、worldview3 画像を元に上記の手法も含め再構築する必要がある。