

# 時系列衛星画像データセットを利用した土地被覆変化箇所の自動判別に関する研究

防災・復興システム工学研究室 市原直人

指導教員 高橋一義

## 1. はじめに

地球観測衛星は広域的かつ長期間継続した地表モニタリングを行うことが可能であるため、土地被覆の変化を捉えるための重要な情報源となっている。その中でも Sentinel-2 衛星シリーズは、無償利用可能な衛星の中で高い地上分解能と回帰日数を持つ。また、観測範囲が全球であることから簡便に地球全体を対象とした自動更新されていく時系列観測データセットが利用可能である。このデータセットと事前に作成した深層学習ネットワークで解析し続けることで、土地被覆変化発生時自動的に土地被覆変化を判別できると考えた。

そこで本研究では、土地被覆を学習データとして事前に作成した深層学習ネットワークによる過去に発生した事象を対象に土地被覆変化の判別を行い、時系列観測データセットを用いた土地被覆変化箇所の自動判別について検討する。

## 2. 使用データ

対象地は 2022 年 8 月 3 日から 4 日にかけて新潟県下越地方で観測された大雨と、2023 年 7 月 10 日に九州北部地方で発生した豪雨によって土砂災害が発生した新潟県村上市荒川下流域、福岡県久留米市田主丸町竹野領域とする。この地域に加えて、学習データとして新潟県新潟市、長岡市、村上市の Sentinel-2 観測データを収集した。また、土地被覆変化箇所の位置を示す正解画像については筆者が目視判別によって作成した。

## 3. 方法

### 3.1 利用する深層学習手法の検討

MathWorks 社の提供するソフトウェア MATLAB を利用して深層学習ネットワークを作成する。事前に深層学習ネットワークを作成すること、教師デー

タの必要がないことから、異常検知アルゴリズムの一つである畳み込みオートエンコーダ (CAE) を採用し、既往研究<sup>1)</sup>の構造を参考にネットワークを作成する。

### 3.2 従来手法による土地被覆変化判別

土地被覆変化判別結果の評価基準として、差分解析による土地被覆変化判別を行った。ここでは土地被覆変化前後の NDVI 画像による差分解析から結果を評価した。本研究では画素値の差分を閾値とし、閾値を 10 刻みで変動させて判別結果を評価する。

### 3.3 予備検討

#### 3.3.1 学習データの検討

土地被覆は広域で同様の特徴を持つという考えの下、複数地域を学習データに使用することで深層学習ネットワークの性能向上に繋がるかを検討した。その際、深層学習ネットワークによる出力画像の再現度評価に、式(1)により計算される構造的類似性指数 (SSIM) を使用する。

$$SSIM(x, y) = \frac{(2\mu_x\mu_y)(2\sigma_{xy})}{(\mu_x^2 + \mu_y^2)(\sigma_x^2 + \sigma_y^2)} \quad (1)$$

x : 画像 y : 出力画像  $\mu_x, \mu_y$  : 局所平均  
 $\sigma_x, \sigma_y$  : 標準偏差  $\sigma_{xy}$  : 相互共分散

#### 3.3.2 土地被覆変化と SSIM の対応関係

土地被覆変化が発生すると SSIM が低下すると考え、新潟県村上市荒川下流域を対象地とした土地被覆変化と SSIM の対応関係を確認する。

### 3.4 CAE による土地被覆変化判別手法

予備検討を踏まえ、複数の変更を加えて改良したネットワークを使用し、土地被覆変化判別を行う。この手法では取得した画像から 3 バンド選択し組み合わせた入力データに加えて、NDBI, NDVI, MNDWI の 3 種の指標画像を組み合わせる入力デ

ータとした 2 ケースの入力データの組み合わせを 2 つの研究対象地にそれぞれ作成した 4 ケースをそれぞれ評価する。

## 4. 結果と考察

### 4.1 従来手法による土地被覆変化判別

差分解析による土地被覆変化判別結果では閾値を高くすれば高くするほど精度と適合率が増加し再現率が低下するトレードオフの関係にあることが示された。判別結果から再現率が 90% と土地被覆変化の取りこぼしが少なく、精度も 80% を超えている閾値 30 の判別結果を評価基準とした (表 1)。

### 4.2 予備検討結果

#### 4.2.1 学習データの検討

単一地域と複数地域をそれぞれ学習データとした深層学習ネットワークにより長岡市の 500m 四方領域を再現させた。その結果を表 2 に示す。この表から複数地域を学習データに使用することで出力画像の再現度向上に繋がることが示された。

#### 4.2.2 土地被覆変化と SSIM の対応関係

土地被覆変化前後の対象地を深層学習ネットワークに再現させた結果を表 3 に示す。この表から、使用した全てのバンドで土地被覆変化後の SSIM が低下していることが確認できる。このことから土地被覆変化が発生すると出力画像の SSIM が低下することが示された。

### 4.3 CAE による土地被覆変化判別

CAE による判別結果を表 4 に示す。この表から、本研究の事前作成した深層学習ネットワークは既往研究・従来手法に及ばないものの、ケース C2 ではこれらに迫る判別結果となった。しかし、学習データに対象地が含まれていないケース C3・C4 では、全ての評価指標が既往研究・差分解析より低く、適合率が著しく低い結果となった。これの要因として、土地被覆変化前後で変化後の方が高い SSIM を示したバンドが存在していたことで適切な閾値を設定できていなかったこと、対象地の土地被覆変化領域が影と重なっていることで、変化した領域が再現されていることが考えられる。

## 5. まとめ

本研究では、事前に作成した深層学習ネットワークで時系列観測データセットを解析し続けることで自動的に土地被覆変化を判別することができるという考えの下、畳み込みオートエンコーダによる土地被覆変化判別を行った。提案手法が既往研究や従来手法に迫る判別結果を示したことから、事前に作成した深層学習ネットワークによる土地被覆変化判別について適用の可能性を示せたと考える。しかし、より適切な閾値の設定方法や、使用する学習データの改善が新たな課題として示された。

### 参考文献

- 1) Hejar Shahabi ら “Unsupervised Deep Learning for Landslide Detection from Multispectral Sentinel-2 Imagery” MDPI Remote Sens. 2021, 13(22), 4698;

表 1 従来手法の判別結果

閾値	精度 (%)	適合率 (%)	再現率 (%)
30	83.1	23.1	90.6

表 2 学習データの検討結果

学習データ	バッチ枚数	SSIM		
		短波長赤外	近赤外	緑
長岡市	2968枚	0.826	0.877	0.807
長岡市 新潟市	7321枚	0.868	0.923	0.844

表 3 土地被覆変化と SSIM の対応関係

	変化前	変化後
短波長赤外	0.819	0.800
近赤外	0.802	0.799
緑	0.723	0.680

表 4 CAE による判別と既往研究<sup>1)</sup>との比較

対象地	No	精度 (%)	適合率 (%)	再現率 (%)
新潟県村上市 荒川下流域	C1	62.7	58.4	59.5
	C2	74.8	68.4	81.9
福岡県久留米市 田主丸町竹野	C3	50.3	16.1	69.0
	C4	52.9	16.3	65.4
インド	既往研究	/	76.0	91.0
中国			72.0	87.0
台湾			77.0	82.0