

衛星画像を使った土地改変分類手法の検討

一般財団法人砂防フロンティア整備推進機構 酒谷 幸彦、西 真佐人、藤澤 誠二、○寺堀 吉博
一般財団法人リモート・センシング技術センター 古田 竜一、清水 孝一、平松 真由
北海道大学低温科学研究所 中田 和輝

1. はじめに

砂防指定地内での無許可の伐採、土砂掘削・盛土構造物の設置等の違法行為が、全国各地で発覚している。中には、違法行為が原因で土砂災害が発生した事案も報告されている。

こうした中、砂防指定地の管理者は、適切な砂防指定地管理を行うために指定地の違反行為を早期に発見し是正措置を講じる必要があり、土地改変の状況を広域、簡易に把握する方法が求められている。

本研究は、砂防指定地管理の効率化に繋がる方策として前年度開発した違法行為の発見抽出プログラムの課題克服のため実装を目指している土地改変分類機能の検討について述べる。

2. 昨年度開発したプログラムの課題

前年度開発したプログラムは、緑植生の茂り具合を示す正規化植生指標(赤色、近赤外バンド使用)を利用し、二時期の変化抽出を行う手法を用いて、植生から裸地への変化を抽出している。そのため、裸地以外の土地改変の抽出(例えば建物の建築や太陽光発電施設の建設など)を行うには、土地改変を分類する方法の検討が必要である。

3. 土地改変分類機能の開発手法

本研究では、土地改変分類機能追加のため、前年度使用した Landsat-8 の Band3 (赤)、Band4 (近赤外) に加えて他のバンドの情報も活用することで土地改変の分類ができないか試行した。多数のバンドを使用するため、多変数、多クラス分類を行う必要があり統計的集約が困難であること、また、適切な分類アルゴリズムの構築が困難であることから AI の種類の一つである機械学習を使用することとした。高い精度の機械学習を行うためにはより良い分類器を作成する必要があるため、分類器を作成する上で重要である学習データの収集、学習データのスペクトル特性、特性を踏まえ作成した分類器の精度について検討を行った。

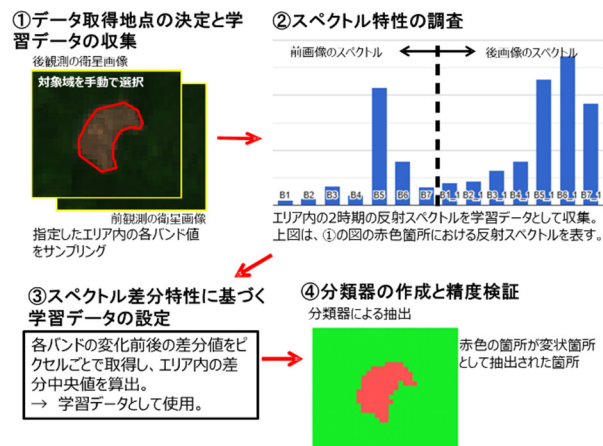


図1 土地改変分類機能の開発手法

表1 使用した Landsat-8 のバンド

バンド	説明	波長 (μm)	解像度(m)
B1	Band1 (青)	0.435-0.451	30
B2	Band2 (青)	0.452-0.512	30
B3	Band3 (緑)	0.533-0.590	30
B4	Band4 (赤)	0.636-0.673	30
B5	Band5 (近赤外)	0.851-0.879	30
B6	Band6 (短波赤外)	1.566-1.651	30
B7	Band7 (短波赤外)	2.107-2.294	30
B10	Band10 (熱赤外)	10.60-11.19	100
B11	Band11 (熱赤外)	11.50-12.51	100

4. データ取得地点の決定と学習データの収集

宅造地、太陽光パネル設置等の土地変状を Google Earth の画像から確認を行い、確認できた箇所を対象に衛星画像 (Landsat-8) から目視により、負例(非変化箇所)を含めて 574 個の学習データを収集した。なお、目視による判別のため、Landsat-8 の 1 画素 (30m) 内に収まっていない箇所は、収集した対象物の大きさ、形状によっては、ミクセルを含んだ学習データとなっている。分類項目は、非変化箇所及び変化箇所(崩壊地・伐採・植生域から構造物への変化・裸地域から構造物への変化)とし、前年度開発業務の中で使用した Landsat-8 変化前後ペア画像を対象とした。

図2は宅造地、裸地への土地変状が確認できる事例(人工改変による裸地・構造物への変化箇所)について、変状前後の2時期のカラー画像を比較し分類した結果である。



図2 目視判読による分類結果
(Landsat-8 画像: 2017 年 9 月 1 日)

表 2 学習データ収集内容及び結果

分類項目	データ数
Forest-Forest	67
Bare-Bare	36
Landslide	123
Deforestation	12
Construction for Forest	108
Construction for bare soil	228
合計	574

5. スペクトル差分特性に基づいた学習設定

収集した学習データを用いて、各クラスのスペクトル差分特性（図 3、4）を調べ、使用する学習データや分類項目について検証を行った。

その結果、「森林から裸地」の変化である Landslide と Deforestation のスペクトル差分特性はおおよそ同じ傾向を示すことがわかったため、機械学習を行う際には、同じクラスにまとめ合計 135 個の学習データとした。同様に、No Change (Forest-Forest) と No Change (Bare-Bare) のクラスは不変化箇所のクラスとしてまとめ、合計 103 個の学習データとした。他の分類項目とは異なるスペクトル差分特性を持つ Construction for Forest のクラスは合計 108 個の学習データ、Construction for bare soil のクラスは合計 228 個の学習データとした。

今回試行した分類器には、日照量や温度などといった季節的な変化による変動の影響が過大であるという先行研究の知見を踏まえ、Landsat-8 データのバンド 1 から 7 までの可視、近赤外および短波長赤外域を使用し、バンド 10、11 の熱赤外波長は、今回の分類には使用しなかった。

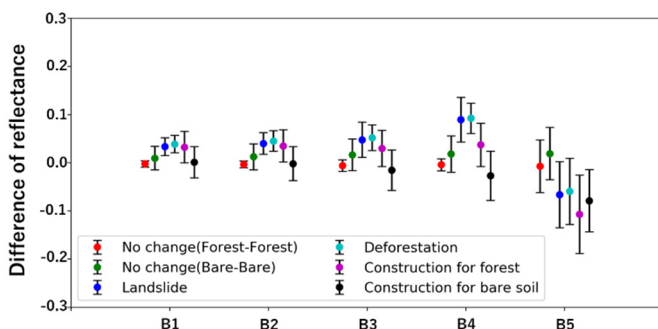


図 3 各クラスのスペクトル差分特性 (B1~B5)
各変化事象における反射率の平均値、標準偏差を示している。(平均値：プロット、標準偏差：バー)

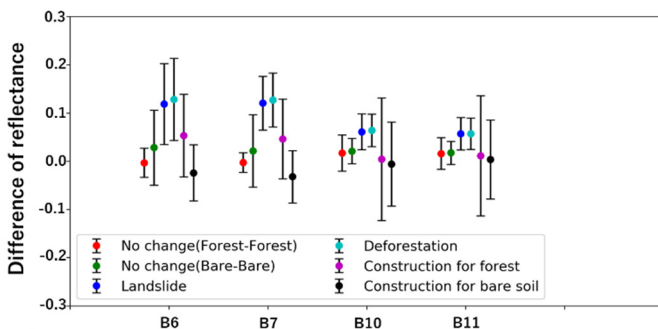


図 4 各クラスのスペクトル差分特性 (B6、B7、B10、B11)

6. 分類器の作成と精度検証

機械学習の手法として、RBF カーネルを用いた SVM (Support Vector Machine) を適用した。分類器の作成の際に、収集した学習データのうち訓練データを 70%、テストデータを 30% として使用し、学習モデルの作成及びテストデータによる精度検証を行なった。その結果を表 3 に示す。

その結果、正解率（総合精度）0.85 を示し、概ね高い精度で分類可能であることが分かった。クラス別で見ると、森林から裸地への変化が適合率（precision）、再現率（recall）ともに 0.95 と高い値を示した。一方、森林から構造物への変化のそれらは相対的に低いことが分かった。また、裸地から構造物への変化は概ね総合精度に近い値を示した。

この結果から、今回検討した分類器は変化箇所の抽出を行うにあたり十分な精度を有していると考えられる。

表 3 SVM による分類結果

Class	precision	recall	f1-score
森林から裸地への変化	0.95	0.95	0.95
森林から構造物への変化	0.67	0.69	0.68
裸地から構造物への変化	0.86	0.82	0.84
変化なし（森林－森林、裸地－裸地）	0.88	0.94	0.91
総合精度	0.85		

7. まとめ

本研究では、土地改変分類機能の実装に際して、学習データの収集、スペクトル特性、特性を踏まえ作成した分類器の精度について検討を行った。

検討の結果、学習データのスペクトル特性に関しては、崩壊地や伐採地、不変化箇所（森林-森林、裸地-裸地）の項目では、おおよそ同じスペクトル差分特性を示した。一方、森林から構造物への変化クラス、裸地から構造物への変化のクラスでは他の分類項目とは異なるスペクトル差分特性を示した。以上の結果を踏まえて、分類項目を調節した。

分類器の精度検証については、森林から構造物への変化を除いては、高い分類精度を有していることがわかった。全体の総合精度は 0.85 であり、砂防指定地の変化箇所の抽出を行うにあたり十分な精度を有していると考えられる。

今回は、伐採に対するデータ数が少ないこと、伐採地と崩壊地が同様のスペクトル差分特性をもつことの 2 つの理由により崩壊地と伐採地を単一クラスとして分類した。しかし、違法な伐採を検出するという観点からは、それらを別のクラスとして分類することが望ましい。今後は、今回少なかった伐採に対するデータ数を増やすことに加え、各クラスの特性を示す特徴量を検討するなどの改善を図っていきたい。

【参考文献】

- 1) 藤澤 誠二他：砂防指定地における衛星画像を使った土地改変抽出手法の検討，2019 年度砂防学会発表会概要集，pp 369-370，2019 年 5 月
- 2) 望月 翔太他：機械学習法を用いた SPOT5/HRG データの土地被覆分類とその精度比較，統計数理，pp 93-103，2016 年 6 月