

衛星画像とUAV空撮画像を併用した 機械学習による河川地被分類手法の検討

RIVERINE LAND COVER CLASSIFICATION TECHNIQUE BY MACHINE LEARNING WITH SATELLITE AND UAV AERIAL IMAGES

佐藤拓也¹・岩見収二²・百瀬文人³・宮本仁志⁴

Takuya SATO, Shuji IWAMI, Akito MOMOSE and Hitoshi MIYAMOTO

¹正会員 修(農) 株式会社建設技術研究所 東京本社河川部 (〒330-6030 さいたま市中央区新都心11-2)

²正会員 博(工) 株式会社建設技術研究所 東京本社河川部 (同上)

³学生会員 芝浦工業大学大学院 理工学研究科建設工学専攻 (〒135-8548 東京都江東区豊洲3-7-5)

⁴正会員 博(工) 芝浦工業大学 工学部土木工学科 教授 (同上)

This paper examined a new method for classifying riverine land covers by using a machine learning technique with both the satellite and UAV(Unmanned Aerial Vehicle) images in the Kurobe River channel. The method employed Random Forests (RF) for the classification with RGBs and NDVIs(Normalized Difference Vegetation Index) of the images in combination. In the method, the high-resolution UAV images made it possible to create accurate training data for the land cover classification in the low-resolution satellite images. The results indicated that the combination of the high- and low-resolution images in the machine learning could effectively detect trees and grasses from the satellite images with a certain degree of accuracy, while the usage of only the low-resolution satellite images could not determine the difference. These results could strongly support the effectiveness of the present machine learning method for grasp the most important areas in riverine vegetation management.

Key Words : river management, land cover classification, satellite image, UAV aerial image, machine learning

1. はじめに

日本の多くの河川では、河道内の樹林化や砂州・みお筋の固定化などが進行し、流下能力の阻害や河川構造物の安定性への影響などが顕在化しつつある。また、本来の河原環境が変化することで河川生態系や河川景観への影響も懸念される。このような河川管理上の課題を把握し適切な河川管理に繋げるためには、河道内の樹林化、砂州・みお筋の固定化などの河川地被状況を継続的に把握することが重要となる。これには通常、航空写真の目視での比較による検討が行われているが、撮影頻度が限られていること、分析手法が写真の比較に限られることなどから、洪水前後の状況変化や季節変化などの高頻度の分析や定量的な比較は困難な状況である。

これに対し、近年、河道管理や河川施設管理でAI(Artificial Intelligence)やUAV(Unmanned Aerial Vehicle)等の新たな技術の活用が進んでおり、作業効率化や定量化

等の観点から河道管理の実務でもこれらの技術の積極的な導入が期待される。UAV空撮を用いた河川地被状況の分析^{1,2)}も実施されるようになってきている。UAV空撮を利用した既往研究では、主に画像のテクスチャーやRGB値および正規化植生指標NDVI(Normalized Difference Vegetation Index)の情報などを用いた植生の自動判別が試みられてきた^{3,4,5)}。木本分類の研究³⁾では、機械学習をUAV空撮のマルチスペクトル画像に適用させ、高木針葉樹林を判別した。RGB情報を基にした植生分類⁴⁾では、UAV空撮のモザイク画像を植生群落ごとに分割して機械学習を適用させている。また、河川植生を対象とした研究⁵⁾では、UAV空撮画像に深層学習を適用させてヤナギの在・不在の自動判別を試みている。これら一連の研究は植生判別に焦点をあてたものであり、それ以外の地被状態の検出は検討されていない。これに対し、百瀬ら⁶⁾は、UAV空撮画像から機械学習により高精度で裸地や水面を含む地被状況を分類する手法を構築しており、河道管理上の課題である樹林化状況等の把握に有用な手法




図-1 黒部川流域の概要と対象地点

表-1 衛星画像の仕様

項目	仕様
衛星名	Dove
画像仕様	B/G/R/近赤外線のマルチスペクトル・バンド
地上分解能	(高度475km) : 3.7m, (高度400km) : 3.0m

として期待される。

一方で、広範囲の地被状況を高頻度で把握する場合、UAV空撮でも相当のコストを要する。これに対し、近年、高頻度撮影の衛星画像が比較的容易に入手可能となっており、広範囲・高頻度での地被状況把握への活用が期待される。衛星画像の河川分野への適用例としては、瀬・淵の可視化⁷⁾や流路変遷の把握⁸⁾⁹⁾、河道内植生の分類¹⁰⁾等の試みがみられるものの、地被状況の経時変化分析など河道管理実務への応用は進んでいない。

本研究では、百瀬ら⁹⁾の地被分類手法をもとに、衛星画像とUAV空撮画像を併用した機械学習による地被分類手法を検討した。その手法を黒部川の樹林化傾向を示す礫床区間に適用することにより実効性の検証を行った。

2. 対象河川

図-1に対象とする一級水系黒部川の概要と観測区間を示す。黒部川は、水源から峡谷を刻みながら北流し、愛本地先（河口から約13km）から下流に扇状地を形成して富山湾に至る幹川流路延長85km、流域面積682km²の日本有数の急流河川である。河口から約13kmの扇状地区間は、礫河原が発達するセグメント1区間であり、近年植生の侵入が認められるようになっている。

本検討で対象とした区間は、扇状地区間の植生の侵入が認められる4-6km区間（図-1に示す赤色プロットの区間）とした。当該区間は、百瀬ら⁹⁾による機械学習の検




図-2 衛星画像 2017/11/7撮影




図-3 UAV空撮画像 2017/11/28撮影




図-4 地被分類手法の流れ

討区間と一致し、UAVによる空中撮影画像が得られている。

3. 機械学習による地被分類手法

(1) 適用画像

本研究では、衛星画像とUAV空撮画像を使用した。適用した衛星画像は、表-1の諸元を有するPlanet社提供の衛星画像であり、全地球を常時撮影しているため、広範囲が概ね3日に一度の頻度で撮影されている。一方、UAVによる空撮は、搭載したマルチスペクトル（R/G/B/近赤外線/レッドエッジ）により撮影された空間分解能約0.5mであり、衛星画像に比較して高解像度の画像が得られている。ここでは、2017年11月に撮影された衛星画像とUAV空撮画像を検討に用いた。解析範囲の衛星画像を図-2に、UAV空撮画像を図-3にそれぞれ示す。また、機械学習に用いる教師データは、図-2および図-3の赤枠内データより抽出した。

(2) 地被分類手法の概要

地被分類手法の流れを図-4に示す。衛星画像、UAV空撮画像のRGB画像より判別してそれぞれの正解データ、




図-5 教師データの地被割合

表-2 検討に用いた教師データと検証データ

項目	4.(2) 衛星画像による地被分類	4.(3) UAV空撮画像による地被分類
教師データ	衛星画像の地被分類と衛星画像のRGB, NDVI	UAV空撮画像の地被分類と衛星画像のRGB, NDVI
地被分類に適用する特徴量	衛星画像のRGB, NDVI	衛星画像のRGB, NDVI
検証データ	UAV空撮画像の地被分類	UAV空撮画像の地被分類

※教師データは図-2, 3の赤枠内のデータから50%をランダムに抽出

表-3 衛星写真を用いた機械学習における検証結果 (F値)

地被分類	特徴量のデータセット		
	RGB	NDVI	RGB+NDVI
水面	0.48	0.57	0.58
裸地	0.82	0.82	0.83
植生	0.89	0.92	0.92
全体	0.78	0.80	0.81

教師データを作成し、衛星画像とUAV空撮画像の併用による地被分類結果を検証した。また、機械学習による地被分類精度の検証には、高解像度のUAV空撮画像より作成した正解データを用いた。なお、正解データは全域を、教師データは図-2, 3の赤枠の範囲を対象とした。

(3) 特徴量のデータセット

特徴量のデータセットは、衛星画像より取得可能なRGB, NDVI, RGB+NDVIとした。衛星画像の画素サイズ約3m×3mを解析単位にして、それぞれのデータセットを用いて機械学習を行い、特徴量の組み合わせが地被分類の精度に与える影響を検討する。

(4) 機械学習アルゴリズム


機械学習のアルゴリズムにはランダムフォレスト¹¹⁾を用いた。ランダムフォレストは決定木と呼ばれる弱い学習器を多数組み合わせる手法である。

ランダムフォレストの実行にはPythonライブラリのscikit-learn¹²⁾を使用した。機械学習で生成される地被分類の結果算出にはデータセットを5分割する交差検証法を用いた。機械学習における分類性能の評価指標には精度(Precision)と再現率(Recall)の調和平均であるF値(F-measure)を用いた。定義を式(1)-(3)に示す。


$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F - measure = \frac{2Precision \cdot Recall}{Precision + Recall} \quad (3)$$



(a) 目視による正解データ



(b) 機械学習による分類結果 (RGB+NDVI)

図-6 衛星画像から作成した教師データを用いた地被分類

ここで、TP(True Positive): 正解データの地被状態を機械学習でも真と判定した画素数, FP(False Positive): 正解データの地被状態以外を機械学習で真と判定した画像オブジェクトの数, FN(False Negative): 正解データの地被状態を機械学習で偽と判定した画像オブジェクトの数である。

4. 適用画像による地被分類性能の比較

(1) 教師データと検証データ


本検討では、機械学習に用いる教師データ、検証データ及び特徴量のデータセットから表-2に示す組合せを設定し、衛星画像のみを用いた場合とUAV空撮画像を併用した場合の地被分類性能を比較した。地被分類の真値となる正解データは、衛星画像、UAV空撮画像それぞれのRGB画像より判別して作成した。衛星画像は解像度が低く、木本・草本の判別が困難であったため、それらをまとめて植生とし、目視判読により水面・裸地・植生の3つに分類した。一方、高解像度のUAV画像は、Momose¹³⁾らの手法により水面・裸地・草本・木本の4分類とし、衛星画像の画素サイズに粗視化した(粗視化の詳細は後述)。教師データは、それぞれの正解データより図-2の赤枠内のデータ(約550m×550m, 画素数29255)から50%をランダムに抽出したものと、同じ画素の特徴量から構成される。モデルの性能を評価するための検証データは、高解像度のUAV空撮画像より作成した正解データを適用した。なお、図-5により教師データの地被状況に偏りが無いことを確認している。

表-4 支配面積率のしきい値を設けた場合の検証結果 (F値)


地被分類	しきい値70% 以上 (93.0%)	しきい値80% 以上 (90.0%)	しきい値90% 以上 (85.9%)
水面	0.65	0.66	0.66
裸地	0.83	0.83	0.83
草本	0.71	0.70	0.70
木本	0.65	0.64	0.65
全体	0.74	0.74	0.74

※特徴量のデータセットはRGB+NDVI

() は図-3の赤枠内の全データに占める割合



(a) UAV空撮画像による正解データ



(c) 機械学習による分類結果 (NDVI)





図-7 UAV空撮画像による正解データの作成方法



(b) 機械学習による分類結果 (RGB)



(d) 機械学習による分類結果 (RGB+NDVI)

図-8 UAV空撮画像から作成した教師データを用いた地被分類結果

表-5 衛星画像とUAV空撮画像を併用した場合の検証結果 (F値)

地被分類	特徴量のデータセット		
	RGB 図-8 (b)	NDVI 図-8 (c)	RGB+NDVI 図-8 (d)
水面	0.59	0.51	0.66
裸地	0.83	0.69	0.83
草本	0.69	0.55	0.70
木本	0.63	0.47	0.65
全体	0.72	0.59	0.74

表-6 教師データの違いによる検証結果の比較 (F値)

地被分類	教師データ	
	衛星画像 (図-6 (b))	UAV空撮画像 (図-8 (d)の草本と木本を植生として評価)
水面	0.58	0.66
裸地	0.83	0.83
植生	0.92	0.93
全体	0.81	0.83

※特徴量のデータセットはRGB+NDVI


(2) 衛星画像に基づく教師データを用いた地被分類

衛星画像から作成した教師データを用いた機械学習に


よる地被分類を行った。結果を図-6に示す。衛星画像より判読可能な水面、裸地、植生は高精度で分類できている。また、表-3のUAV空撮画像から作成した正解データに対するF値は水面を除き概ね0.8以上の精度となっている。一方で、樹林化状況を把握するには、衛星画像の解像度の低さから木本と草本の判別が困難であり、河道管理の実務への適用に課題がある。

(3) UAV空撮画像に基づく教師データを用いた地被分類

UAV空撮画像は、衛星画像に比べ高解像度である。そこで、図-7に示すようにUAV空撮画像を衛星画像の画素サイズに粗視化した。そのとき、衛星画像の画素サイズ内でUAV空撮画像の支配面積が最も大きい地被状況を衛星画像の画素サイズでの地被状況とした。ただし、その支配面積率がモデルの性能に影響を与える可能性があるため、正解データとする画素を抽出する際に支配面積率のしきい値 (70%以上, 80%以上, 90%以上) を設けた場合の検証結果 (F値) を比較した。その結果、表-4に示すように、F値にはしきい値の変化による大きな差はみられない。その理由は、全データの約85%で、真値




(a) 2017/9/9撮影




(b) 2018/6/24撮影


図-9 撮影時点の異なる衛星画像 (RGB画像)




(a) ケース① (2017/9/9)



(b) ケース① (2018/6/24)



(c) ケース② (2017/9/9)



(d) ケース② (2018/6/24)

図-10 撮影時点の異なる衛星画像による地被分類結果 (RGB+NDVI)

表-7 教師データセットの組合せ

項目	ケース①	ケース②
特微量のデータセット	衛星画像 (2017/11/7) のRGB+NDVI	衛星画像 (2017/9/9, 2018/6/24) のRGB+NDVI
正解データ	UAV空撮画像 (2017/11/28)	UAV空撮画像 (2017/11/28)

となった地被状況の割合が各画素面積の9割以上を占めているためである。よって、本研究ではしきい値を設定しないこととした。

UAV空撮画像から作成した教師データを用いて機械学習による地被分類を行った。結果を図-8に示す。UAV空撮画像の教師データを用いたことにより、一部再現性に課題があるものの、衛星画像より分類困難であった木本と草本の判別や、視認困難な水面の再現など地被分類が可能となっている。特微量のデータセットの違いによる比較からは、RGB+NDVIのデータセットを

用いることで表-5の正解データに対するF値0.75程度の精度が確保できる。また、表-6に示すように、木本と草本を植生として水面・裸地・植生の3分類でのF値を算定した場合、衛星画像のみの検証結果よりも精度が高い。

5. 撮影時点の異なる衛星画像への適用

前項の結果より、高解像度のUAV空撮画像を用いることで同時期に撮影された衛星画像から木本・草本を比較的高い精度で分類できることを示した。一方、河道管理上植生域の経年変化の把握が重要であることから、UAV空撮画像による機械学習結果を異なる時期の衛星画像に適用できれば、植生の経年変化の効率的な分析が期待できる。そこで、以下の2ケースの方法により、撮影時点の異なる2017年9月9日と2018年6月24日の衛星画像へ適用することを試みた。適用したデータセット等の組合せを表-7に示す。

ケース①：前項の学習結果を撮影時点の異なる衛星

画像に適用した場合

ケース②：各衛星画像の特徴量データセット (RGB+NDVI) と撮影時点の異なるUAV空撮画像による地被分類結果を教師データとして機械学習に用いて広範囲の地被分類に適用した場合

特徴量データセットは、前項で最も再現性の高いと判断したRGB+NDVIとした。また、ケース②では、図-9の赤枠内のRGB+NDVIと図-8(a)の正解データをもとに教師データを作成した。

2017年9月9日、2018年6月24日撮影の衛星画像を図-9に示す。UAV空撮画像と同時期の2017年11月7日撮影の衛星画像(図-2)と比較すると、撮影時点の流量の違いにより水域と裸地域に違いがみられるものの、植生域の変化はほとんどみられない。一方で、地被状況に変化がない箇所でもRGB画像に色の変化がみられ、その特性も図-9のように異なっているが、これは樹木の葉量や大気の状態の違い等により放射輝度が異なるためと推察される。

各ケースの地被分類結果を図-10に示す。ケース①の場合、撮影時点の異なる衛星画像より作成したモデルでは、地被状況のほか大気の状態により放射輝度が異なるため、精度よく地被状況を分類することができない。図-10(a)と(b)の結果を比較しても、地被分類結果が大きく異なることから、放射輝度の違いによる影響が大きいことが確認できる。一方、ケース②では、ある1時点のUAV空撮画像(2017年11月28日撮影)による地被分類結果を真値として機械学習を行うことにより、異なる2時点の衛星画像からの地被分類の同定精度が大きく向上している。この期間では、撮影時点が異なっても地被状況に大きな変化がないため、撮影時期の異なるUAV空撮画像を真値として適用することにより、精度の向上が図れたものと推察される。水域と裸地域、木本域と草本域の分類精度に課題が残るものの、植生域に着目すれば、概ね同定可能となっている。

6. 結論

本研究では機械学習に高解像度のUAV画像を併用することにより、衛星画像がもつ地被分類情報(木本と草本の分類等)を精度よく引き出せることを示した。衛星画像は一般的に解像度に限界があり、そこに内在する詳細な地被分類情報の目視での判読にも限界がある。本研究での高解像度のUAV画像を併用した手法は、それらを十分補完しており、河道管理上重要な植生域の把握に有用な手法である。

参考文献

- 1) 飯村隼多, 宮本仁志, 井上敏也, 千ヶ崎祐夏, 浜口憲一郎: UAV計測による洪水インパクトが鬼怒川の河道植生に与えた影響評価, 土木学会論文集B1(水工学), Vol.73, No.4, pp.I_1069-I_1074, 2017.
- 2) 赤堀良介, 溝口 敦子, 石黒 聡士: 網状流路を有する大井川における植生域消失と流路変動の関係, 河川技術論文集, 第24巻, pp.215-220, 2018.
- 3) Franklin, S.E., Ahmed, O.S., and Williams, G.: Northern Conifer Forest Species Classification Using Multispectral Data Acquired from an Unmanned Aerial Vehicle, Photogrammetric Engineering & Remote Sensing, 83(7), pp. 501-507, 2017.
- 4) 鈴木太郎, 土屋武司, 鈴木真二, 山場淳史: 小型UAVによる空撮画像からのスーパーピクセル分割と機械学習を用いた植生分類手法の構築, 日本リモートセンシング学会誌, 36, pp.59-71, 2016.
- 5) 齋藤正徳, 湧田雄基, 市川健, 天谷香織, 那須野新, 大石哲也, 池内幸司, 石川雄章: UAV及び深層学習を用いた植生の自動判別による河道維持管理手法の開発, 土木学会論文集B1(水工学), Vol.74, No.4, pp.I_829-I_834, 2018.
- 6) 百瀬文人, 宮本仁志, 岩見収二, 永矢貴之: ウェーブレット変換と機械学習を用いたUAV河川空撮画像の地被分類手法の検討, 土木学会論文集B1(水工学)Vol.74, No.5, pp.I_607-I_612, 2018.
- 7) 桑原祐史, 町田聡, 黒台昌弘, 大林成行: 高空間分解能衛星データを用いた河川の水面抽出および瀬と淵の可視化に関する研究-国土防災リモートセンシング研究会河川防災ワーキンググループ活動報告-, 日本リモートセンシング学会誌, Vol.25, No.5, pp.482-489, 2005.
- 8) 宇民正, 村本嘉雄: 河道変遷調査への衛星画像解析の適用, 水工学論文集, 第41巻, pp.965-970, 1997.
- 9) 藤井壽生, 西川肇, 工藤勝輝, 伊藤一正, 近藤勉, 木田哲量, 今野誠: 衛星データを活用した利根川の流路変遷に関する研究, 土木学会論文集G, Vol.64, No.1, pp.1-9, 2008.
- 10) 高橋俊守, 加藤和弘, 松下容一郎, 村山昌史, 安岡善文: 多時期IKONOSデータと分類樹木を用いた河道内植生分類に関する研究水工学論文集, 第49巻, pp.1429-1434, 2005.
- 11) Andreas C. Muller, Sarah Guido著, 中田秀基訳: Pythonではじめる機械学習, 373p, (株)オライリー・ジャパン, 2017.
- 12) scikit-learn 0.19.1 documentation: <http://scikit-learn.org/stable/#>, 2018.05.27閲覧.
- 13) Momose, A., S. Iwami, T. Nagaya, H. Miyamoto: Examination of Machine Learning Algorithms for Riverine Landscape Classification in UAV Remote Sensing Images, 12th ISE2018, 2018.

(2019. 4. 2受付)