

複数時点の衛星画像を用いた 機械学習による河川地被変化の検出手法

A MACHINE LEARNING TECHNIQUE FOR DETECTING RIVERINE LAND COVERS USING SATELLITE IMAGES IN DIFFERENT TIMES

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正会員 修(工) 株式会社建設技術研究所 東京本社河川部 (同上)

⁴正会員 博(工) 芝浦工業大学 工学部土木工学科 教授 (〒135-8548 東京都江東区豊洲3-7-5)

This paper examined a new method for detecting riverine land covers by using a machine learning technique with the satellite images in different times in a Kurobe River channel. In the method, UAV (Unmanned Aerial Vehicle) images were used to train the machine learning method in several small portions where the type of riverine land covers was precise and no land cover change occurred between the different times. From these UAV images and the corresponding feature values (i.e., RGBs and Near-InfraRed) in the satellite images, accurate training data were created for the land cover detection in the whole extent of the satellite images. The results showed that the present method could detect riverine land covers at the multiple different times with high accuracy, in particular, the details of land cover change such as decreases in water surface and losses of vegetation due mainly to a flooding.

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

1. はじめに

日本の多くの河川において、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河川管理上の課題が顕在化している。この課題を解決していくためには、植生や砂州・みお筋など河道内の地被変化を継続的に把握し、それらの状態や変化のメカニズムを踏まえた適切な河川管理を実施することが重要となる。しかしながら、地被変化の把握に従来からある航空写真の目視による方法は、状態を高頻度に把握することが困難であるため、中小洪水による地被変化をその都度把握することが難しい。

これに対して、近年、樹林化や砂州の固定化等の河川管理上の課題を把握し、適切な河川管理を実践していくために、AI (Artificial Intelligence)やUAV(Unmanned Aerial Vehicle)等の新技術が積極的に活用されてきている。

UAV空撮画像は、比較的容易に高解像度の画像を取得できることから、地被分類に活用する研究が進められており、画像のRGB情報などに機械学習などのAI手法を適用させた植生の自動判別や河川の地被分類が試みられている¹⁻⁹⁾。鈴木ら¹⁾は、UAV空撮画像のRGB情報をもとに機械学習によって植物分類を試みている。また、斎藤ら²⁾は、UAV画像に深層学習を適用させ、ヤナギの在・不在の自動判別を行っている。さらに、百瀬ら^{3,4)}は、UAV空撮画像から機械学習を用いて河川の地被状況を精度よく分類する手法を構築している。その一方で、UAV空撮でも広範囲の地被状況を高頻度で把握するためには、相当の労力やコストがかかることが課題となっている。

そこで筆者ら⁵⁾は、近年、比較的容易に入手可能となっている高頻度撮影の衛星画像に着目し、効率的かつ高精度に河川地被状況を検出する手法を検討してきた。衛星画像を用いて土地被覆分類を行った既往研究には、




図-1 黒部川流域の概要と対象地点

表-1 衛星画像・UAV空撮画像の仕様

項目	衛星画像	UAV空撮画像
衛星／製品名	Dove (Planet社)	eBee (senseFly社製)
画像仕様	B/G/R/近赤外線	B/G/R/近赤外線/ レッドエッジ
地上分解能	約3.0m	約0.1m

船越ら⁹⁾が、災害前後の衛星画像および機械学習を用いて山地部における土砂移動箇所の自動抽出を試みている。また、衛星画像の河川分野への適用例としては、河川流路変遷の把握⁷⁾や河道内植生の分類⁹⁾等が挙げられる。しかしながら、筆者らの知る限りでは、河道管理の実務において必要な精度で水面や砂州を含む河川の地被状況を検出する手法の検討は未だ十分には行われていない。

筆者らの前報⁹⁾では、高頻度で取得可能な衛星画像と同時期に撮影されたUAV空撮画像を併用した機械学習により、高精度で地被状況を分類する手法を構築した。その一方で、複数時点の衛星画像から地被変化を検出する手法の開発に対しては、撮影時点の大気の状態などによる放射輝度の変化に伴う地被検出精度の劣化が課題として残されていた。したがって、これらの手法を適切な河川管理に繋げていくためには、複数時点の地被状況変化を効率的、高精度に把握する手法の確立が重要となる。

本研究では、前報⁹⁾の地被分類手法を拡張し、機械学習により撮影時点の異なる衛星画像から、河川地被変化を検出する手法を検討し、黒部川において植生の侵入がみられる区間を対象にしてその有用性を検証した。

2. 対象河川

対象とする一級水系黒部川の概要と解析区間を図-1に示す。本検討で対象とする区間は、礫河原が発達するセグメント1区間で、近年植生の侵入が認められる河口か




図-2 UAV空撮画像 2017/11/28撮影




図-3 UAV空撮画像 2018/11/5撮影




図-4 愛本観測所流量（日流量）と使用画像の撮影日




図-5 衛星画像 2017/11/7撮影




図-6 衛星画像 2018/11/8撮影

ら4-6km区間（図-1に示す赤色プロットの区間）とした。当該区間では、筆者ら³⁾により図-2および図-3に示す2017年11月と2018年11月の2時点のUAV空撮画像が得られている。また、対象河川ではUAV空撮画像の2時点間に、図-4に示すように2018年7月6日に国土交通省所管の愛本観測所（河口から13.4km）で日流量632m³/sの出水（以下、2018年7月出水）が発生し、当該区間では植生の流出や河岸侵食が確認されている。




図-7 地被検出手法の流れ

3. 機械学習による河川地被変化の検出方法

(1) 使用画像

本研究では、表-1に示す衛星画像とUAV空撮画像を使用した。衛星画像は、当該区間では概ね3日に一度の頻度で撮影されており、比較的容易に高頻度で入手可能であるPlanet社提供の画像を使用した。一方、図-2および図-3に示すUAV空撮画像は、地上分解能が約0.1mであり、衛星画像よりも高解像度となっている。

前報⁹⁾では、衛星画像と同時期に撮影された高解像度のUAV空撮画像を併用し、衛星画像に内在する詳細な地被分類情報をうまく検出することで精度よく河川地被状況を分類可能であることを示した。本研究では、その手法を拡張し複数時点の衛星画像に適用して地被分類を行うために、図-4に示すUAV空撮画像が存在する2時期間に撮影された衛星画像を選定し、それら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。使用した衛星画像は、図-5、図-6に示すUAV空撮画像と同時期に撮影された2017年11月7日、2018年11月8日に、これらの期間内に発生した2018年7月出水前後の3時点を加えた計5時点の画像を使用した。

(2) 地被検出手法の流れ

本研究の地被検出手法の流れを図-7に示す。2時点における高解像度のUAV空撮によるRGB画像をもとに、各時点の地被状況を対象範囲全域で判別して正解データ（水面、裸地、草本、木本の4分類）を作成し、機械学習による分類精度の検証に使用した。その際、正解データは衛星画像の画素サイズ約3m×3mに粗視化してある。粗視化の詳細は前報⁹⁾を参照されたい。作成した正解データのうち、2017年11月から2018年11月までの期間で地被変化が生じず地被分類が明確な図-2および図-3の赤枠内データ（画素数7,991）を機械学習に用いる教師データに使用した。また、衛星画像より取得可能なRGB、近赤外線から特徴量データセットを作成した。これらの正解データと特徴量データセットからなる教師データを用いて機械学習を行い、正解データを作成した2時点の

表-2 検討に用いた教師データと検証データ

項目	ケース①	ケース②	ケース③
教師データ (図-2、 図-3の 赤枠内)	特徴量 (衛星画像) ・ 2017/11/7	特徴量 (衛星画像) ・ 2017/11/7 ・ 2018/11/8	特徴量 (衛星画像) ・ 2017/11/7 ・ 2018/6/25 ・ 2018/7/2 ・ 2018/7/10 ・ 2018/11/8
正解データ (UAV空撮画像)	・ 地被分類が明確で2017/11/28～2018/11/5 で地被変化が生じていない範囲の地被分類		
検証 データ (全域)	特徴量 (衛星画像) ・ 2017/11/7 ・ 2018/11/8		
正解データ (UAV空撮画像)	・ 2017/11/28の地被分類 ・ 2018/11/5の地被分類		

※教師データは図-2、3の赤枠内のデータから作成

※特徴量は表中の時期に撮影された衛星画像のRGB+近赤外値を使用

地被状況について、対象範囲全域を対象に機械学習による地被分類結果の精度を検証した。

(3) 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¹⁰⁾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-learn¹¹⁾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。

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


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

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


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像オブジェクト数、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数である。

4. 機械学習による河川地被分類の精度比較


本研究では、複数時点の衛星画像を組み合わせた以下の3ケースの教師データによる機械学習を対象範囲全域に適用し、2時点（2017年11月、2018年11月）の地被分類の精度を検証した。教師データの組合せを表-2に示す。
ケース①：1時点（2017年11月）の教師データによる機械学習結果を異なる撮影時点（2018年11月）の衛星画像に適用した場合




(a) UAV空撮画像による正解データ



(b) 機械学習による分類結果 (ケース①)



(c) 機械学習による分類結果 (ケース②)



(d) 機械学習による分類結果 (ケース③)

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-3 2017年11月の地被分類検証結果の比較 (F値)

地被分類	特徴量のケース		
	ケース①	ケース②	ケース③
水面	0.66	0.66	0.65
裸地	0.83	0.82	0.83
草本	0.60	0.64	0.64
木本	0.59	0.61	0.58
全体	0.72	0.72	0.72

※特徴量のデータセットはRGB+近赤外線

表-4 2018年11月の地被分類検証結果の比較 (F値)

地被分類	特徴量のケース		
	ケース① 図-8 (b)	ケース② 図-8 (c)	ケース③ 図-8 (d)
水面	0.68	0.78	0.77
裸地	0.89	0.89	0.91
草本	0.00	0.65	0.62
木本	0.47	0.59	0.55
全体	0.63	0.79	0.79

※特徴量のデータセットはRGB+近赤外線

ケース②：2時点（2017年11月，2018年11月）の教師データによる機械学習結果を同じ撮影時点の衛星画像に適用した場合

ケース③：検証データ以外の時点を含む5時点の教師データによる機械学習結果をそのうちの2時点の衛星画像に適用した場合

機械学習結果をもとに，2時点の地被分類を行った結果を図-8に，それぞれの時点のF値を表-3，表-4に示す。

1時点の衛星画像を教師データとしたケース①では，撮影時点の異なる2018年11月の地被分類を行った結果，表-4に示すF値は0.6程度であり，図-8(b)では草本が検出されていない。図-5，図-6に示した2時期の衛星画像を比較すると，同じ地被状況でも2時期のRGB画像の色調





図-9 地被別面積変化の比較 (2017年11月～2018年11月)

が大きく異なっており，特に2018年11月8日撮影の衛星画像では目視による草本の検出が困難となっている。これは，大気の状態の違いなどによる放射輝度が異なっているためであり，その影響によりケース①の地被分類結果（図-8(b)）では草本が検出されなかったと推察される。

一方，2018年11月の衛星画像を含めた教師データを用いたケース②，③では，表-4に示すF値で0.8程度の精度が確保できる。また，表-3に示す2017年11月の地被分類もF値0.7程度の精度が確保できている。図-8に示した正解データと機械学習による地被分類を比較しても，一部




図-10 撮影時点の異なる衛星画像による地被分類結果 (RGB+近赤外線)

植生の分類精度に課題があるものの、衛星画像の目視より判別困難な水面と裸地の判別など、広範囲の地被状況を十分な精度で同定可能となっている。

5. 河川地被変化の検出性能の精度検証

(1) 地被別面積変化の比較

まず、2時点 (2017年11月、2018年11月) の機械学習 (ケース③) による地被分類結果をもとに各時点の地被別面積変化を算出し、UAV空撮画像 (正解データ) による地被別面積変化と比較した。結果を図-9に示す。機械学習による河川地被変化では、草本と木本の増減傾向に課題があるものの、河道各部における水面の減少や裸地の増加等、全体として地被変化を的確に捉えていることが確認できた。

(2) 2018年7月出水による河川地被変化の検出

次に、比較的高い再現性が得られたケース③の機械学習を、出水期間を含めた3時点 (2018年6月25日、7月2日、7月10日) の衛星画像に適用し、2018年7月出水による地被状況変化を検出した。その結果を図-10に示す。3時点の衛星画像 (RGB画像) を比較すると、大気の状態の違い等により放射輝度が異なるため、同じ地被状況でも

RGB値が異なっていることが推察される。これに対し、5時点すべての特徴量を教師データに加えることで、衛星画像の目視からでは判別困難な草本や木本が検出されている。ただし、その検出精度は前項で示した精度の誤差を内包している。また、2018年7月10日は他の時点に比べて流量が多いが、流量が異なる場合でも水面 (みお筋) が精度よく抽出されている。出水中の時系列変化に着目すると、図-10(b) と(c)に赤丸で例示した出水期間中に発生したみお筋の下流延伸や出水後の植生流出などが機械学習結果からも確認できる。このことから、本手法は出水による河道応答を詳細に把握可能であることが示唆される。

正解データと機械学習による地被分類をもとに、2017年11月から2018年11月までの地被変化の比較結果を図-11に示す。図-11(b)の機械学習による水面などの地被変化は、図-11(a)のUAV空撮画像の正解データをもとに抽出した地被変化と概ね一致する。さらに、機械学習により抽出した地被変化では、図-11(b)に赤丸で示した2018年7月出水により流出した植生が検出されているほか、図-11(a)に赤枠で示した部分で出水により河岸の一部が侵食されて植生が流出している状況が確認できる。以上の結果から、本提案手法は河道管理上重要となるみお筋や植生の変化を把握可能であることが示された。




図-11 2017年11月-2018年11月の地被変化の比較

6. 結論

本研究では、機械学習を用いて複数時点の衛星画像から河川地被変化を効率的、高精度に検出できることを示した。地被変化が生じていない範囲で教師データを作成し、判別する衛星画像の特徴量を教師データに加えることで、出水による植生流出やみお筋変化などの河川地被変化を検出することが可能となることが示された。また、提案した手法は中長期の河川地被変化についても定量的に把握可能であることが示唆されたことから、河道管理上重要な河川地被変化の把握に有用な手法である。今後の課題としては、本手法による地被検出精度が河道管理の実務において必要となる精度を確保できているか検証することなどが挙げられる。

参考文献

- 1) 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.
- 2) 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.
- 3) 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.

- 4) 百瀬文人, 佐藤拓也, 岩見収二, 永矢貴之, 宮本仁志: 機械学習による複数時期での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.75, No.2, pp.I_667-I_672, 2019.
- 5) 佐藤拓也, 岩見収二, 百瀬文人, 宮本仁志: 衛星画像とUAV空撮画像を併用した機械学習による河川土地被覆分類手法の検討, 河川技術論文集, 第25巻, pp.199-204, 2019.
- 6) 船越和也, 織田和夫, 角田里美, 服部聡子, 松田昌之, 屋木わかな, 太井正史, 池田義太郎: 高頻度光学衛星を用いた土砂移動域抽出手法の検討, 2019年度砂防学会研究発表会概要, P.069, pp.509-510, 2019.
- 7) 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.
- 8) 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.
- 9) 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.
- 10) 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.
- 11) scikit-learn 0.22.2 documentation: <http://scikit-learn.org/stable/#>, 2020.3.25閲覧.

(2020.4.2受付)