



Title	尾瀬地域における衛星リモートセンシングによる植生モニタリング手法の検討
Author(s)	平山, 英毅; Hirayama, Hidetake; 富田, 瑞樹 他
Citation	低温科学, 80, 343-352
Issue Date	2022-03-31
DOI	https://doi.org/10.14943/lowtemsci.80.343
Doc URL	https://hdl.handle.net/2115/84980
Type	departmental bulletin paper
File Information	22_p343-352_LT80.pdf



尾瀬地域における衛星リモートセンシングによる植生 モニタリング手法の検討

平山 英毅¹⁾, 富田 瑞樹¹⁾, 原 慶太郎¹⁾

2021年9月30日受付, 2021年10月29日受理

衛星リモートセンシングによる, 尾瀬地域の生態系の広域かつ長期に亘るモニタリングに資する植生図作成手法について検討した. 尾瀬地域は年間を通して雲や雪氷に覆われるため, 解析に利用可能な衛星データの数が限られる. 本研究では, 高時間分解能を有する Sentinel-2 衛星による 2016 年 1 月から 2019 年 11 月に亘るデータから, 計 12 枚となる月毎のモザイク画像を整備した. まず, 急傾斜地で影の影響が大きいためにそれを除去するモザイク処理手法を確立した. 整備したモザイク画像を用いて機械学習のランダムフォレストにより, 相観に基づく 9 つのクラスに分類した. これらの処理により精確な植生図を作成する手法を確立することができた (総合精度 = 0.93, カッパ係数 = 0.92).

An examination of vegetation mapping techniques for Oze region using satellite remote sensing

Hidetake Hirayama¹, Mizuki Tomita¹, Keitarou Hara¹

We examined a method of vegetation mapping for wide-scale and long-term monitoring of ecosystems in the Oze Region using satellite remote sensing. This area is often covered with clouds and snow throughout the year, therefore the number of satellite data available for analysis is limited. We prepared 12 monthly mosaic images from the Sentinel-2/MSI data from January 2016 to November 2019. First, we established a mosaic processing method to remove the influence of shadow on steep slopes. Using the mosaic images, we classified them into 9 physiognomic classes by random forest of machine learning. A method to produce an accurate vegetation map was established by these processes (Overall accuracy = 0.93, Kappa coefficient = 0.92).

キーワード: 植生図, 衛星リモートセンシング, モザイク処理, 機械学習, Sentinel-2
vegetation mapping, satellite remote sensing, mosaicking, machine learning, Sentinel-2

1. はじめに

尾瀬地域は, 高層湿原である尾瀬ヶ原と, その周囲には燧ヶ岳や至仏山等の 2,000 m 級の山々からなる景観を有し, 学術的に貴重な動植物が生育・生息している (尾瀬保護財団, 2017). 2007 年には, 尾瀬国立公園として指定され, 生態系や生物多様性の保護・保全が図られてきたが, 近年においては, ニホンジカの侵入による植生の攪乱や, 気候変動に伴う集中豪雨が尾瀬の生態系・生物多様性に及ぼす影響が懸念されている (鈴木・蛭間, 2017). このような背景から, 2017 年には 4 次尾瀬総合学術調査が開始された (尾瀬保護財団, 2017; 尾瀬国立

責任著者

平山英毅

連絡先

〒265-8501 千葉県千葉市若葉区御成台4-1

Tel: 043-236-4628

e-mail: hh207501@rsch.tuis.ac.jp

1) 東京情報大学総合情報学部

1 Faculty of Informatics, Tokyo University of Information Sciences, Chiba, Japan

公園協議会, 2017). 尾瀬地域の適正な生態系管理のためには, その主要構成要素である植生の分布を把握することが肝要であることから, 調査課題の一つには, 広域かつ長期に亘る植生モニタリングシステムの構築があげられた(鈴木・蛭間, 2017).

広域かつ長期に亘る植生の把握には, 衛星リモートセンシング技術を用いたモニタリング手法がきわめて有効である(Xie et al., 2008; Adam et al., 2010). さらに, 近年では, AI(Artificial Intelligence:人工知能)技術の一つである機械学習手法を用いた土地被覆分類手法に関する研究が進められている(Sharma et al., 2017; Hirayama et al., 2018; Boudewijn et al., 2020; Ramezan et al., 2021). 特に, 機械学習手法のひとつであるランダムフォレスト(Breiman, 2001)を解析に用いることで, 高精度な分類処理が可能になることが多くの研究で示されている(Zhu, 2013; Zhou, 2018; Mishra et al., 2021). 一方, 年間を通して雲や雪氷に覆われることが多い地域では, 地表面の情報を一度の観測により得ることが困難である. これまでに, 筆者らは, Landsat-8/OLI データを整備することで, 特定の観測年に対する1枚のモザイク画像を作成する手法を提案するとともに, ランダムフォレストを解析に用いることで相観に基づく8クラス(広葉樹林, 針葉樹林, 湿原低木, 湿原草地, 低木・草地, 水域, 市街地, 裸地)が高い精度で分類できることを示してきた(平山ほか, 2018). 一方で, 植生図の高度化に向けた課題としては, (1)これまでのモザイク手法では濃い雲の影が残るため, 手法の改良が必要であること, (2)前報における8クラスに加えて落葉や常緑の分類を行うには, 年毎ではなく高頻度のモザイク画像を作成する必要があること, 加えて, (3)衛星リモートセンシ

ングデータの分類に機械学習手法を用いるためには, 衛星データの整備のみならず, 教師データの効率的な整備方法(Inglada et al., 2017)が必要であることを指摘した.

本稿では, これらの課題を解消するために, 衛星データと機械学習手法を用いた植生図(以下, 衛星植生現況図)の作成手法を検討した結果を報告する. 具体的には, 衛星植生現況図を作成するために, Landsat-8/OLI データよりも高い空間分解能と時間分解能を有している Sentinel-2/MSI データを解析に用いた. 収集した Sentinel-2/MSI データから被雲率が高いシーンと欠損データを除くと, 2016年1月から2019年11月の間で286シーンのデータを解析に供することができた. それらの286シーンを用いて12枚の月毎のモザイク画像を整備し, ランダムフォレストにより衛星データを解析することで, 分類クラス数を増やしつつ, 高い分類精度を持つ衛星植生現況図を作成した. この過程で雲・雪氷および影を除去するためのモザイク手法を確立した.

2. データと方法

2.1 解析対象範囲

尾瀬国立公園およびその周辺(尾瀬地域)を解析対象とした(図1). 尾瀬地域の森林帯には, 落葉広葉樹林であるブナ林と常緑針葉樹林であるオオシラビソ林が広く分布している(前田・宮川, 1976; 濱尾・大沢, 1984). また, 尾瀬国立公園の周辺には, 落葉針葉樹林であるカラマツ人工林がみられる. 加えて, 湿原には日本最大級の高層湿原である尾瀬ヶ原のほか, 周辺の山岳の緩斜面には湿原が多数点在する.

2.2 衛星データの収集

Sentinel-2/MSI および Sentinel-1/C-SAR により観測された画像を収集・整備し, 解析に用いた. Sentinel-2/MSI は欧州宇宙機関(ESA)により運用されている陸域観測を主目的とした光学衛星であり, 現在は2機(2A, 2B)の人工衛星によって地球上の任意の地点を5日に一度の頻度で, 地表面の反射光や放射光を13の帯域で観測することが可能である(表1). Sentinel-1/C-SAR は, 合成開口レーダーからマイクロ波を放射し, 地表面から反射されるマイクロ波の後方散乱強度を測定する. 本研究では, 植生の季節変化を収集するため, 高い時間分解能を有する Sentinel-2/MSI 画像, および Sentinel-1/C-SAR を用いた. 衛星画像は, Copernicus Open Access Hub (<https://scihub.copernicus.eu/>) から収集した. Sentinel-2 画像によって2016年1月から2019年

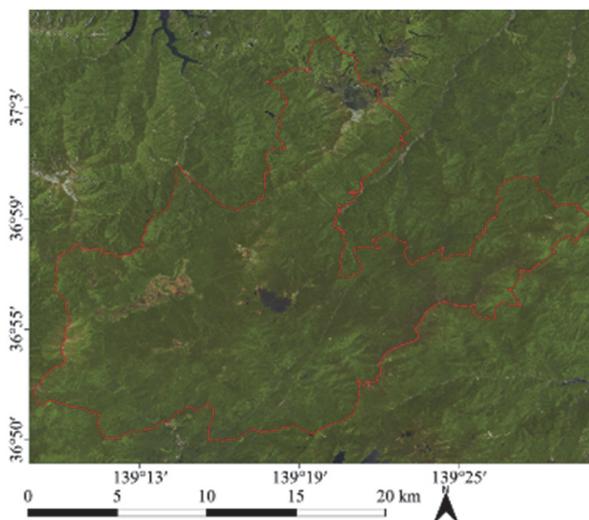


図1: 解析対象範囲. 背景図は Sentinel-2/MSI による6月の合成データ. 図中の赤枠は尾瀬国立公園の境界を表す

11月の間に観測された640シーンを収集し、Level2Aプロダクトに変換した。画像の被雲状態と欠損を考慮し、286シーンを解析に用いた。Sentinel-1画像によって2018年5月から8月に観測されたシーンから、月毎に1シーンずつを解析に用いた。なお、Sentinel-2/MSIおよびSentinel-1/C-SARデータの空間分解能を10mに統一するために、Sentinel-2/MSIのバンド2を基準にした最近傍法によるリサンプリングを実施した。

2.3 月毎のモザイク画像の作成

モザイク処理の前処理として、収集した衛星データに対して、ESA (2018) に示されるシーン分類アルゴリズムを適用し、各画素が雲や雪氷と区分されるかを示す図(品質評価画像)を作成した。本研究では、この品質評価画像をシーンごとに作成することで、雲や雪氷である可能性が高い画素を特定し、該当する画素を除去した。加えて、濃い影に覆われた領域の多くが、青色波長の反射率が0.015以下であったため、これらの領域を影領域とみなし一律に除去した。

雲や積雪、濃い影を除去した各シーンを観測月毎に重ね合わせることで観測月毎のモザイク処理を実施した。この際、各画素の代表値の決定には、月内における青色波長帯が最小値を取る画素値を代表値とする方法である最小青チャンネル法(竹内・安岡, 2004a)を適用した。衛星上で観測された画素値には、太陽光が大気を通過する際のレイリー散乱によって見かけ上の反射率が增大する影響が含まれている。このレイリー散乱の影響を受けやすい波長帯は青色であることが竹内ほか(2004a)に

よって確認されており、また、青色が最小値をとるとき、その画素におけるレイリー散乱の影響は最も小さいと考えられているため、最小青チャンネル法をモザイク処理に適用した。

これらのモザイク処理手法によって、2016年1月から2019年11月に亘るSentinel-2/MSIデータを元に12枚の月毎のモザイク画像を作成した。

2.4 植生クラスのカテゴリ処理

2.4.1 機械学習による教師付き分類処理

機械学習手法の一つであるランダムフォレスト(Breiman, 2001)を用いて植生クラスのカテゴリ処理を実施した。機械学習に供する特徴量として、月毎のモザイク画像からバンド9を除く反射率(12バンド)と、反射率から算出した12個の指数(表2)を月ごとに整備し、解析に用いた。また、Sentinel-2/MSIとSentinel-1/C-SARを組み合わせることで、植生図上に発生するごま塩上の誤分類の分布が小さくなる効果が期待できる(Liu et al., 2019)。このことからSentinel-1/C-SARによる観測データとして、5月から8月の4ヵ月分のVH偏波およびVV偏波を用いることで、計296個の特徴量を植生分類に供した。

2.4.2 教師データおよび検証データ

分類に用いるクラスは、環境省による統一凡例区分と尾瀬ヶ原の現地調査(2017年9月4日から6日、2018年9月2日から4日)から、9つのクラス(落葉広葉樹林、常緑針葉樹林、落葉針葉樹林、湿性草地1(ツルコケモミズゴケクラス)、湿性草地2(ヌマガヤオーダー、ヨシクラス)、低木・草地、水域、構造物、裸地)とした(表3)。

教師データおよび検証データの整備のために、環境省1/25,000植生図(2009年から2011年の調査;以下、環境省植生図)から10,000ポイントが無作為抽出し、同一画素内に発生したポイントを除く9,963ポイントを作成した。無作為抽出によって得られる各クラスのポイント数は、対象地内における各クラスの面積に依存して大きく異なった(表3)。クラスごとの教師データの出現割合が不均衡である場合、ランダムフォレストが出現数の少ないクラスを無視して解析してしまう既知の問題がある(Japkowi and Shaju, 2002; Visa and Ralescu, 2005)。本研究では、教師データの不均衡問題に対して、合成マイノリティ・オーバーサンプリング技法(Synthetic minority over-sampling technique :

表1: Sentinel-2/MSI (2A,2B) が有するバンド (ESA 2021)

No.	バンド 名称	中心波長 (nm)		空間分解能 (m)
		2A	2B	
1	Coastal aerosol	442.7	442.3	60
2	Blue	492.4	492.1	10
3	Green	559.8	559.0	10
4	Red	664.6	665.0	10
5	RedEdge 1	704.1	703.8	20
6	RedEdge 2	740.5	739.1	20
7	RedEdge 3	782.8	779.7	20
8	NIR	832.8	833.0	10
8A	Narrow NIR	864.7	864.0	20
9	Water vapour	945.1	943.2	60
10	SWIR - Cirrus	1373.5	1376.9	60
11	SWIR1	1613.7	1610.4	20
12	SWIR2	2202.4	2185.7	20

表2: 植生分類に供した指数. RENDVIはRedEdge 1,2,3の各バンドをそれぞれ組み入れた3つの指数を算出した

指数	式	参考文献
正規化植生指数 Normalized Difference Vegetation Index (NDVI)	$\frac{NIR - RED}{NIR + RED}$	Rouse et al., (1974)
拡張植生指数 Enhanced Vegetation Index (EVI)	$2.5 \frac{NIR - RED}{(NIR + 6RED - 7.5BLUE) + 1}$	Huete et al., (2002)
レッドエッジ正規化植生指数 1 Red Edge Normalized Difference Vegetation Index 1(RENDVI-1)	$\frac{NIR - RedEdge1}{NIR + RedEdge1}$	
レッドエッジ正規化植生指数 2 Red Edge Normalized Difference Vegetation Index 2(RENDVI-2)	$\frac{NIR - RedEdge2}{NIR + RedEdge2}$	Gitelson and Merzlyak 1994
レッドエッジ正規化植生指数 3 Red Edge Normalized Difference Vegetation Index 3(RENDVI-3)	$\frac{NIR - RedEdge3}{NIR + RedEdge3}$	
改良クロロフィル吸収率指数 Modified Chlorophyll Absorption Ratio Index (MCARI)	$\{(RedEdge1 - RED) - 0.2(RedEdge1 - GREEN)\} / (RedEdge1 / RedEdge1)$	Daughtry et al., (2000)
正規化水指数 Normalized Difference Water Index (NDWI)	$\frac{RED - SWIR1}{RED + SWIR1}$	Mcfeters 1996
正規化湿潤指数 Normalized Difference Moisture Index (NDMI)	$\frac{NIR - SWIR1}{NIR + SWIR1}$	Gao 1996
正規化土壌指数 Normalized Difference Soil Index (NDSI)	$\frac{SWIR1 - NIR}{SWIR1 + NIR}$	竹内・安岡 2004b
輝度指数 Brightness Index (BI)	$\sqrt{\left(\frac{RED \times RED}{GREEN \times GREEN}\right) \div 2}$	Escadafal et al., (1989)
土壌調整植生指数 Soil Adjusted Vegetation Index (SAVI)	$\frac{NIR - RED}{NIR + RED + L} (1 + L)$	Huete 1988
正規化都市化指数 Normalized Difference Built-up Index (NDBI)	$\frac{SWIR2 - NIR}{SWIR2 + NIR}$	Zha et al., (2003)

表 3：統一凡例区分に対する本研究で用いる植生クラスとグランドトゥールースデータの整備ポイント数

統一凡例区分	植生クラス	ポイントの数	
		無作為抽出	SMOTE
ウダイカンバ群落 ウラジロヨウラクーミヤマナラ群団 オオバクロモジミズナラ群集 ササダケカンバ群落 ジュウモンジシダーサワグルミ群集 シラカンバ群落 ダケカンバ群落 (I I I) チシマザササブナ群団 ハルニレ群集 ミヤマハンノキ群落 ヤナギ高木群落 (I V) ヤマハンノキ群落	落葉広葉樹林	5013	1,000
アカミノイヌツゲクロベ群集 オオシラビソ群集 マイヅルソウコメツガ群集 シラビソオオシラビソ群集 スギ・ヒノキ・サワラ植林	常緑針葉樹林	128	1,000
カラマツ植林, カラマツ群集	落葉針葉樹林	3603	1,000
ツルコケモモミズゴケクラス	湿性草地 1	81	1,000
ヌマガヤオーダー ヨシクラス	湿性草地 2	176	1,000
コケモモハイマツ群集 コメバツガザクラーミネズオウ群集 ササ群落 (I I), ササ群落 (V) ススキ群団 (V) チシマザサ群落(I I), チシマザサ群落(I I I) なだれ地自然低木群落 蛇紋岩地植生(I) 雪田草原 伐採跡地群落(V)	低木・草地	876	1,000
開放水域	水域	74	1,000
残存・植栽樹群をもった公園, 墓地等 市街地 造成地 自然裸地	構造物 裸地	6 6	1,000 1,000

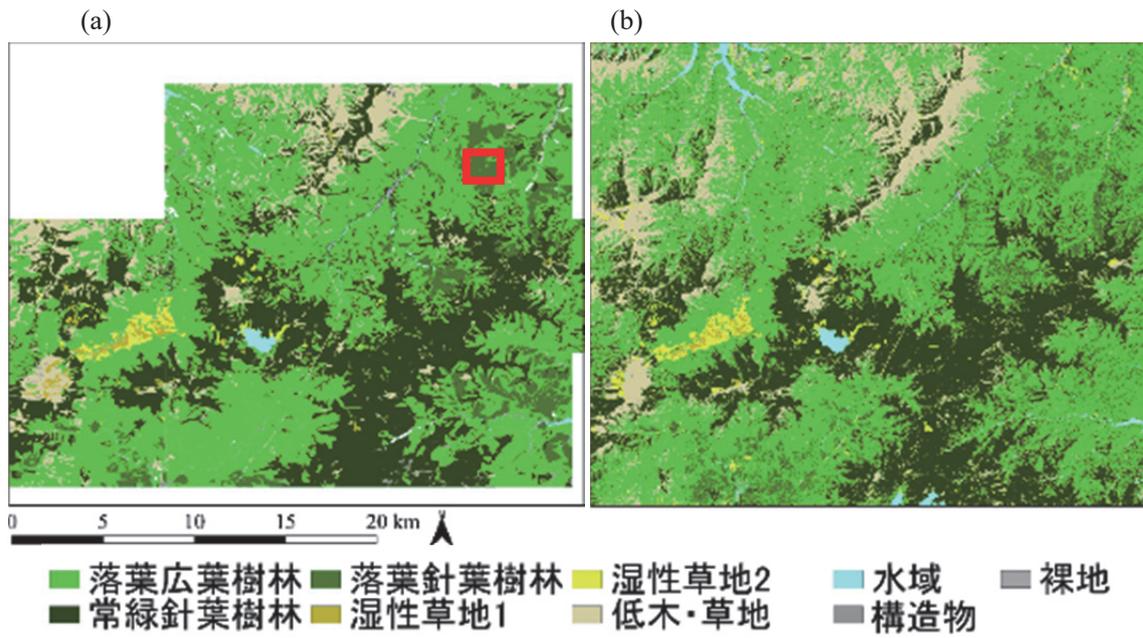


図2：俯瞰図。(a) 環境省 1/2.5 万植生図 (9 クラス統合), (b) 衛星植生現況図。(a) に示す赤枠は図3の拡大図で示す領域

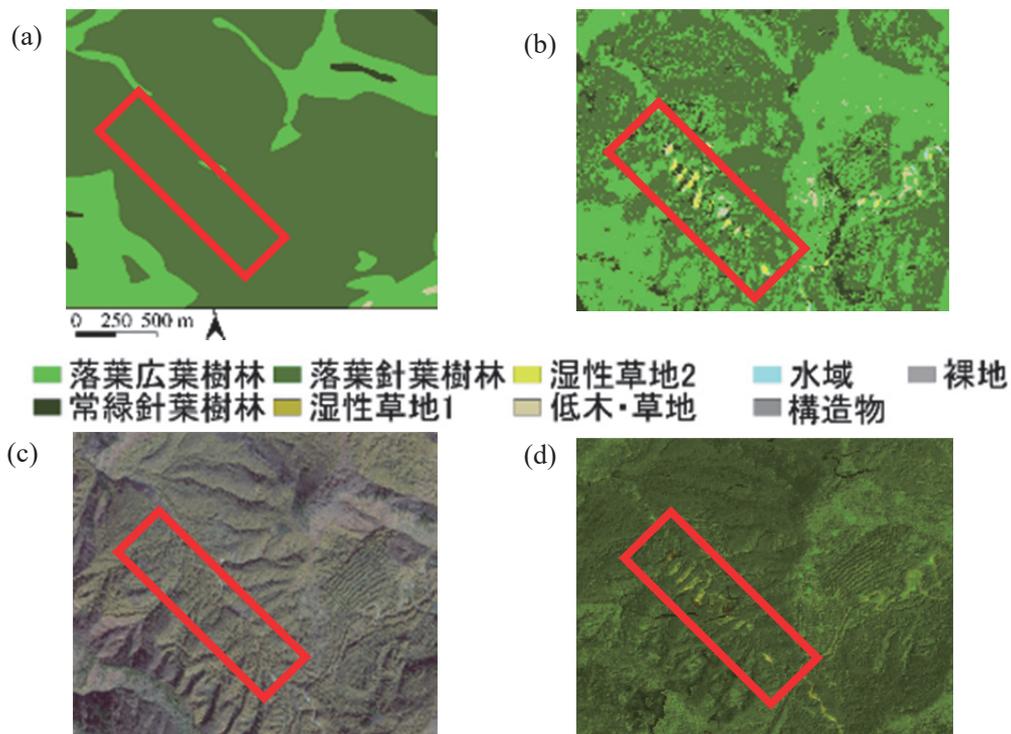


図3：図2における赤枠範囲の拡大図。(a) 環境省植生図 (9 クラス統合), (b) 衛星植生現況図, (c) Google Earth (2014年10月30日撮影), (d) Sentinel-2/MSI (6月モザイク画像)。(b) に示す赤枠は植生クラスが変化したことを確認した範囲

SMOTE) ; (Chawla et al, 2002) を適用し, 各クラスが出現する割合を均一にした. 最終的には, 教師データとしてクラス毎に 750 ポイント, 検証データとして 250 ポイントを整備した.

3. 結果

3.1 月毎のモザイク画像の整備

雲と雪氷そして影の影響が除去された月毎のモザイク画像を整備することができた. 雲と雪氷の領域は, 品質評価画像では検出しきれなかった薄雲についても, 最小青チャンネル法をモザイク処理に採用したことで適切に除去できていた. さらに, 影の領域について, 青色波長の値に閾値を設定したことで, その大半を除去することができた. 整備したモザイク画像から地表面の大部分を観測でき, 展葉や紅葉・落葉等の植生の季節変化を的確に捉えることができていた.

3.2 衛星植生現況図

衛星植生現況図における植生クラスの分布パターンは, 同じ分類基準で統合した環境省植生図の分類クラスの分布パターンと非常に類似していることが確認できた (図 2-a, b). また, 図 2-a の白色の領域は, 2017 年 9 月時点では自然環境調査 Web-GIS (<http://gis.biodic.go.jp/webgis/index.html>) にてデータ公開されていなかった領域であるが, 衛星植生現況図では公開済みの領域から無作為抽出した教師データを整備することでクラスの分布図を補完できた. さらに, 拡大図 (図 3) からは,

2009-2011 年の調査により整備された環境省植生図 (図 3-a) と 2014 年 10 月 30 日に撮影された画像 (図 3-b) において落葉針葉樹林が分布していた領域の一部が, 2016 年以降の Sentinel-2/MSI データを用いたモザイク画像 (図 3-d) と衛星植生現況図 (図 3-b) では低木・草地や湿性草地 2 クラスに変化したことが示された. この落葉針葉樹林クラスの分布は, 環境省植生図における統一凡例ではカラマツ植林に区分されていた領域であり, Sentinel-2/MSI の 2016 年以降のデータを用いたモザイク画像 (図 3-d) や, Google Earth が提供している 2015 年以降の空中写真から当該箇所の樹林が伐採等により除去され, 裸地や草地に変化したことが確認できた.

ランダムフォレストによる植生分類モデルの精度検証の結果, 非常に高い分類精度 (総合精度 = 0.93, カップ係数 = 0.92) が示された. 精度検証の結果 (表 4), 植生クラス毎の分類精度として, 落葉針葉樹林, 湿性草地 1 および 2, 水域, 構造物, 裸地の 6 クラスが特に高い精度で分類された (精度 \geq 0.96). 一方, 落葉広樹林, 常緑針葉樹林, 低木・草地の 3 つのクラスは, それぞれのクラス間における不一致が発生していた.

4. 考察

本研究で確立したモザイク処理手法によって, Sentinel-2/MSI データから月毎のモザイク画像を整備することができた. 整備した月毎のモザイク画像をランダムフォレストによって解析することで, 非常に高い分類精度 (総合精度 = 0.93, カップ係数 = 0.92) を有する 9 つの分類クラスからなる植生分類モデルが構築できた

表 4: 植生分類モデルの精度検証表

		衛星植生現況図								
		落広	常針	落針	湿1	湿2	低・草	水域	構造物	裸地
環境省植生図 (統合)	落広	186	29	9	0	0	25	1	0	0
	常針	32	201	1	0	3	13	0	0	0
	落針	0	0	250	0	0	0	0	0	0
	湿1	0	0	0	250	0	0	0	0	0
	湿2	0	0	0	0	250	0	0	0	0
	低・草	16	20	0	0	5	209	0	0	0
	水域	0	0	0	0	0	0	250	0	0
	構造物	0	0	0	0	0	0	0	250	0
	裸地	0	0	0	0	0	0	0	0	250
	精度	0.79	0.80	0.96	1.00	0.96	0.84	0.99	1.00	1.00

(表4). そして, 環境省植生図では2017年9月以前にはデータが公開されていなかった領域を, 衛星植生現況図では補完することができていた(図2-b).

4.1 高精度な植生分類モデルが構築できた要因

近年では, 衛星データを用いた植生分類に深層学習や機械学習処理を適用することによって高精度な分類モデルが構築できるようになってきた(Sharma et al., 2017; Hirayama et al., 2018; Boudewijn et al., 2020; Ramezan et al., 2021). 一方で, 深層学習や機械学習を用いて高精度な分類モデルを構築するためには膨大な数の教師データを整備する必要があることや(Chi et al., 2008; Abdi, 2020), 整備した教師データにおけるクラス間のデータ数が不均一である場合には, 分類精度が低下することが報告されている(Prati et al., 2015; Waldner et al., 2017). さらに, 既知の植生図を教師データとして用いることができるが, 植生図作成以降の景観変化によっては誤った教師データとなることに留意した解析手法の検討が必要である(Inglada et al., 2017). 以上のことから, 衛星データを用いた植生分類において教師データの整備は, 最も重要な課題だと言える.

本研究で作成した植生分類モデルの総合精度が0.93と非常に高かったことから, 本研究の教師データの収集方法と解析手法が適切であったと考えられた. また, 最も精度が低かった落葉広葉樹林クラスでも0.79の精度があった. これは, 本研究で確立した手法による月毎のモザイク画像から季節情報が得られ, その季節情報をランダムフォレストによって適切に処理できたためだと考えられた. 教師データの整備手法に関しては, 9クラスに統合した環境省植生図をもとに, 調査地面積の総画素である11,982,419画素に対して0.01%未満である10,000点を無作為に整備することで, 相観に基づく9クラスに的確な教師データを収集できることを明らかにした.

4.2 植生クラスの変化抽出への利用可能性

本対象地における環境省植生図は, 2009-2011年に亘る調査によって作成された地図図である. それに対して衛星植生現況図は2016年から2019年のSentinel-2/MSIデータを用いて作成された. それぞれの植生図におけるクラスの分布を比較すると, 常緑針葉樹林が分布していた領域が, 低木・草地や湿性草地2クラスに変化した領域が確認された(図3-b). 当該領域について, それぞれの調査年代に近い空中写真(図3-c)や衛星写真(図3-d)を確認すると, この植生クラスの変化は, 誤分類

ではなく, 実際の変化を的確に表現できていることを確認した.

精度検証(表4)において, 環境省植生図と衛星植生現況図とは不一致の発生も確認された. 衛星植生現況図が最新の植生クラスの分布を表現できていた結果を踏まえると, この不一致は, 植生分類モデルの誤分類ではなく, 植生変化を的確に検出できた可能性がある. つまり, 時間的経過などにより, 真値とした既存植生図の一部が誤りを含んでいる場合においても, 本研究で確立した手法による分類モデルは, 広域的な植生モニタリングに有効であると考えられた.

5. まとめ

尾瀬国立公園とその周辺域を対象とした衛星植生現況図の作成において, 本研究で確立した手法による月毎のモザイク画像と多量な教師データをランダムフォレストによって解析することが有効であることが明らかとなった. さらに, Sentinel-2/MSIデータの高い時間分解能によって, 月毎のモザイク画像を整備したことで, 相観に基づく9つのクラスから構成される衛星植生現況図を作成することができた. 本研究で確立した植生図の作成手法によって, Sentinel-2衛星による長期かつ継続的な観測データを解析することで, 的確な植生把握が可能になり, さらに長期的な植生モニタリングが可能になると考えられた.

謝辞

本研究は, 第4次尾瀬総合学術調査の一環として, 環境省の生物多様性保全推進支援事業費を用い実施した. また, 本研究の一部は, JSPS科研費JP19H04320の助成を受けて実施した. 基礎調査部会の鈴木邦雄部会長には, 調査の方向性について全体にわたってご教示いただきました. 調査地の植生に関しては, 東京農業大学鈴木伸一教授に現地調査に同行いただき, ご教示いただきました. ここに謝意を表します.

引用文献

Abdi, A. M. (2020) Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. *GIScience Remote Sens.*, **57**, 1–20. <https://doi.org/10.1080/15481603.2019.1650447>

- Adam, E., O. Mutanga and, D. Rugege (2010) Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: A review. *Wetl Ecol Manag*, **18**, 281–296. <https://doi.org/10.1007/s11273-009-9169-z>
- Boudewijn, van L., Z. Tobak, and F. Kovács (2020). Machine learning techniques for land use/land cover classification of Medium resolution optical satellite imagery focusing on temporary inundated areas. *Journal of Environmental Geography*, **13**(1–2), 43–52. <https://doi.org/10.2478/jengeo-2020-0005>
- Breiman, L. (2001) Random forests. *Mach Learn*, **45**, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chawla, N. V., K. W. Bowye, L. O. Hall, and W. P. Kegelmeyer (2002) SMOTE: Synthetic minority over-sampling technique. *J Artif Intell Res*, **16**, 321–357. <https://doi.org/10.1613/jair.953>
- Chi, M, R. Feng, and L. Bruzzone (2008) Classification of hyperspectral remote-sensing data with primal SVM for small-sized training dataset problem. *Adv Sp Res*, **41**, 1793–1799. <https://doi.org/10.1016/j.asr.2008.02.012>
- Daughtry, C. S. T., C. L. Walthall, M. S. Kim, et al (2000) Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sens Environ*, **74**, 229–239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)
- ESA (2018) Sentinel-2 Level-2A Algorithm Overview. In: ESA. <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/level-2a/algorithm>. Accessed 15 Jan 2020
- ESA (2021) MultiSpectral Instrument (MSI) Overview. <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>. Accessed 9 Apr 2021
- Escadafal, R., M. C. Girard, and D. Courault (1989) Munsell soil color and soil reflectance in the visible spectral bands of landsat MSS and TM data. *Remote Sens Environ*, **27**, 37–46. [https://doi.org/10.1016/0034-4257\(89\)90035-7](https://doi.org/10.1016/0034-4257(89)90035-7)
- Gao, B. C. (1996) NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens Environ*, **58**, 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gitelson, A, and M. N. Merzlyak (1994) Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. *J Photochem Photobiol B Biol*, **22**, 247–252. [https://doi.org/10.1016/1011-1344\(93\)06963-4](https://doi.org/10.1016/1011-1344(93)06963-4)
- 濱尾章二, 大沢雅彦 (1984) 尾瀬におけるオオシラビソ林の更新. *森林立地*, **26**, 20–24. https://doi.org/10.18922/jife.26.1_20
- Hirayama, H., R. C. Sharma, M. Tomita, and K. Hara (2018) Evaluating multiple classifier system for the reduction of salt-and-pepper noise in the classification of very-high-resolution satellite images. *Int J Remote Sens*, **40**, 2542–2557. <https://doi.org/10.1080/01431161.2018.1528400>
- 平山英毅, 富田瑞樹, 原慶太郎 (2018) 衛星リモートセンシングによる尾瀬植生図作成手法の検討 (特集 情報システム). *東京情報大学研究論集*, **22**, 75–84
- Huete, A. (1988) A soil-adjusted vegetation index (SAVI). *Remote Sens Environ*, **25**, 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Huete, A, K. Didan, T. Miura, E.P. Rodriguez, X. Gao, and L. G. Ferreira (2002) Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens Environ*, **83**, 195–213
- Inglada J, A. Vincent, M. Arias, B. Tardy, D. Morin, and I. Rodes (2017) Operational high resolution land cover map production at the country scale using satellite image time series. *Remote Sens*, **9**, 95. <https://doi.org/10.3390/rs9010095>
- Japkowi, N., and S. Shaju (2002) The class imbalance problem: A systematic study. *Intell Data Anal*, **6**(5), 203–231
- Liu, S., Z. Qi, X. Li, and A. Yeh (2019) Integration of convolutional neural networks and object-based post-classification refinement for land use and land cover mapping with optical and SAR data. *Remote Sens*, **11**, 690. <https://doi.org/10.3390/rs11060690>
- 前田禎三, 宮川清 (1976) 尾瀬地方の亜高山帯森林植生と更新. *森林立地*, **17**, 18–33
- Mcfeters, S. K. (1996) The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *Int J Remote Sens*, **17**:1425–1432. <https://doi.org/10.1080/01431169608948714>
- Mishra, A.P., I. D. Rai, D. Pangtey, and H. Padalia (2021) Vegetation characterization at community level using Sentinel-2 Satellite Data and Random Forest Classifier in western Himalayan foothills, Uttarakhand. *J. Indian Soc. Remote Sens*, **49**, 759–771. <https://doi.org/10.1007/s12524-020-01253-x>
- 尾瀬保護財団 (2017) 平成 28 年度版尾瀬保護レポート. <https://www.oze-fnd.or.jp/wp4/wp-content/uploads/2015/07/da029d0111bfeb23474c9b8ae5aff63f.pdf>. Accessed 22 Feb 2018
- 尾瀬国立公園協議会 (2017) 第 14 回 尾瀬国立公園協議会会議資料. <https://www.env.go.jp/park/oze/data/index.html>. Accessed 22 Feb 2018
- Prati, R.C., G. E. A. P. A. Batista, and D. F. Silva (2015) Class imbalance revisited: a new experimental setup to assess the performance of treatment methods. *Knowl Inf Syst*, **45**, 247–270. <https://doi.org/10.1007/s10115-014-0794-3>
- Ramezan, C. A., T. A. Warner, A. E. Maxwell, and B. S. Price (2021) Effects of training set size on supervised

- machine-learning land-cover classification of large-area high-resolution remotely sensed data. *Remote Sensing*, **13**(3), 1–27. <https://doi.org/10.3390/rs13030368>
- Rouse, Jr J., R. H. Haas, J. A. Schell, and D. W. Deering(1974)Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec Publ*, **351**,309
- Sharma, R. C., K. Hara, and H. Hirayama(2017)A machine learning and cross-validation approach for the discrimination of vegetation physiognomic types using satellite based mltispectral and mltitemporal dta. *Scientifica(Cairo)*, **2017**, 1–8. <https://doi.org/10.1155/2017/9806479>
- 鈴木邦雄, 蛭間啓(2017)第4次尾瀬総合学術調査の展望. 自然環境復元研究, **9**, 35–39
- 竹内渉, 安岡善文(2004a)MODIS データを用いた合成画像作成手法の開発. 写真測量とリモートセンシング, **43**, 36–48. https://doi.org/10.4287/jsprs.43.5_36
- 竹内渉, 安岡善文(2004b)衛星リモートセンシングデータを用いた正規化植生, 土壌, 水指数の開発. 写真測量とリモートセンシング, **43**, 7–19. https://doi.org/10.4287/jsprs.43.6_7
- Visa, S., and A. Ralescu(2005)Issues in mining imbalanced data sets-a review paper. *Proc 16th midwest Artif Intell Cogn Sci Conf*, 67–73.
- Waldner, F., D. C. Jacques, and F. Löw(2017)The impact of training class proportions on binary cropland classification. *Remote Sens Lett*, **8**, 1123–1132. <https://doi.org/10.1080/2150704X.2017.1362124>
- Xie, Y., Z. Sha, and M. Yu(2008)Remote sensing imagery in vegetation mapping: a review. *J Plant Ecol*, **1**, 9–23. <https://doi.org/10.1093/jpe/rtm005>
- Zha, Y, J. Gao, and S. NI(2003)Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *Int J Remote Sens*, **24**, 583–594
- Zhou, T, Z. Li, and J. Pan(2018)Multi-feature classification of multi-sensor satellite imagery based on dual-polarimetric sentinel-1A, landsat-8 OLI, and hyperion images for urban land-cover classification. *Sensors*, **18**, 1–20. <https://doi.org/10.3390/s18020373>
- Zhu, X.(2013)Land cover classification using moderate resolution satellite imagery and random forests with post-hoc smoothing. *J. Spat. Sci*, **8596**, 1–15. <https://doi.org/10.1080/14498596.2013.819600>