

特集 情報システム

原著論文

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

平山英毅*・富田瑞樹**・原 慶太郎**

要旨：温暖化などによる植生への影響が懸念されてきていることを背景として、第4次尾瀬総合学術調査が開始された。学術調査では、長期かつ広域を対象としたモニタリングシステムの構築が研究課題の一つとしてあげられたが、尾瀬は年間を通して積雪や雲に覆われることが多いため、植生の広域的把握には課題が残る。そこで本稿では、尾瀬ヶ原湿原と周辺山地の植生分布の現状を明らかにするために、衛星リモートセンシングを用いた相観植生図作成手法を検討した。Landsat/OLIにより観測された2014年（88シーン）、2015年（86シーン）、2016年（94シーン）の計268シーンの衛星画像を収集した。撮影年度ごとにモザイク処理することで、雲と雪氷を除去した年度ごとの画像を整備した。現地調査と環境省植生図にもとづく情報からグラントゥールズデータを整備し、機械学習の一つであるランダムフォレストにより解析することで、全体精度0.9以上と非常に高精度な相観植生図を作成できた。

キーワード：衛星リモートセンシング、モザイク、尾瀬国立公園、相観植生図、機械学習

An Examination of Vegetation Mapping Techniques for
Ozegahara Moor and Surrounding Mountains using Satellite Remote Sensing

Hidetake HIRAYAMA*, Mizuki TOMITA** and Keitarou HARA**

Abstract: The Fourth Oze Scientific Research Project was initiated due to concern over the impact of global warming on vegetation in the Oze Region. One aim of the project is to develop a system for efficient monitoring of wide scale vegetation changes. The Oze Region, however, is often covered with snow and clouds throughout the year, making monitoring of wide scale changes challenging. This research examined a method for using satellite remote sensing data to create a physiognomic vegetation map for Ozegahara Moor and the surrounding mountains. A total of 268 Landsat/OLI images were recorded in 2014 (88 scenes), 2015 (86 scenes) and 2016 (94 scenes). The images were processed by removing clouds and snow and mosaicked for each year. Ground truth data were prepared based on field survey information and extant vegetation maps produced by the Ministry of the Environment, and the mosaicked images were classified using the Random Forests machine learning system. The results showed an overall accuracy of over 0.9, indicating that this system is able to generate highly accurate physiognomic vegetation maps over a wide area.

Keywords: Satellite remote sensing, mosaics, Oze national park, Physiognomic vegetation map, Machine learning

*東京情報大学 大学院総合情報学研究科
Graduate School of Informatics, Tokyo University of Information Sciences

2018年5月8日受付

2018年8月2日受理

**東京情報大学 総合情報学部

Faculty of Informatics, Tokyo University of Information Sciences

1. はじめに

尾瀬ヶ原は学術的に貴重な湿原生態系を有する本州最大の湿原である[1][2]。これまで、尾瀬地域の自然環境に関する学術調査が、1950年、1977年、1994年の3回にわたり実施されてきており、その結果、尾瀬の湿地生態系としての価値が評価され、2005年にはラムサール条約湿地に登録された。さらに、2007年には尾瀬国立公園に指定されることで保護や管理がなされてきたが、2017年には、温暖化に伴う豪雨の頻度の増加などによる植生への影響が懸念されてきていることを背景として、第4次尾瀬総合学術調査が開始された[3][4]。

今回の学術調査では、尾瀬生態系の長期かつ広域を対象としたモニタリングシステムの構築が基礎研究課題の一つとしてあげられた。面積が372km²にも達する尾瀬国立公園全域を対象とした植生の把握には、衛星リモートセンシングによる観測が有効である。また、山々に囲まれる当該地域においては現地調査が困難なために環境省植生図が未整備の領域があることから、衛星リモートセンシングの活用が期待される。一方で、尾瀬国立公園の大部分は冬季から春季にかけて積雪に覆われ、夏季や秋季においても雲に覆われることが多いため、地表面の情報を一度の観測により得ることは困難であり、広域的な植生の把握には課題が残る。

近年、Landsat Missionsにより提供されているプロダクトであるQuality Assessment (QA) バンドを用いることで、衛星画像上において大気などの影響を受けている場所を効率的に特定できるようになってきた[5]。また、機械学習による衛星画像を用いた土地被覆分類手法に関する研究が進んできたことから[6-7]、衛星画像や機械学習に用いるデータを整備することで、尾瀬国立公園を対象とした長期かつ広域的なモニタリングが可能になることが期待できる。また、植生図のひとつである相観植生図は、植物群落の優占種などの外観を捉えた植生区分で表現されるため、衛星リモートセンシングを用いた相観植生図の作成の際には、対象地の植物群落を可能な限り適切に表現する分類クラスを検討する必要がある。

そこで本稿では、衛星リモートセンシングによる尾瀬ヶ原湿原と周辺山地の植生分布の現状を明らか

にするために相観植生図作成手法を検討した結果を報告する。具体的には、雲や積雪を除去した画像を整備するため、Landsat/OLIによって2014年から2016年の間に取得された計268シーンの画像を収集し、雲と雪氷を除去したモザイク画像をそれぞれの年ごとに作成した。また、尾瀬ヶ原を対象とした現地調査ならびに、環境省植生図にもとづく情報から約10,000ポイントのグランドトゥルースデータを整備するとともに、適切な分類クラスを検討し、機械学習の一つであるランダムフォレストにより解析することで高精度な相観植生図を作成した。最後に、今後の課題と検討事項を整理した。

2. データと方法

2.1 研究対象地

尾瀬国立公園の全域を研究対象地とした(図1)。尾瀬国立公園の大部分は、夏緑樹林であるブナ林と、針葉樹林であるオオシラビソ林から構成される[2]。これらの山地に囲まれた範囲に本州最大の湿原である尾瀬ヶ原湿原や尾瀬沼、その他の小面積の湿地が多数分布している。

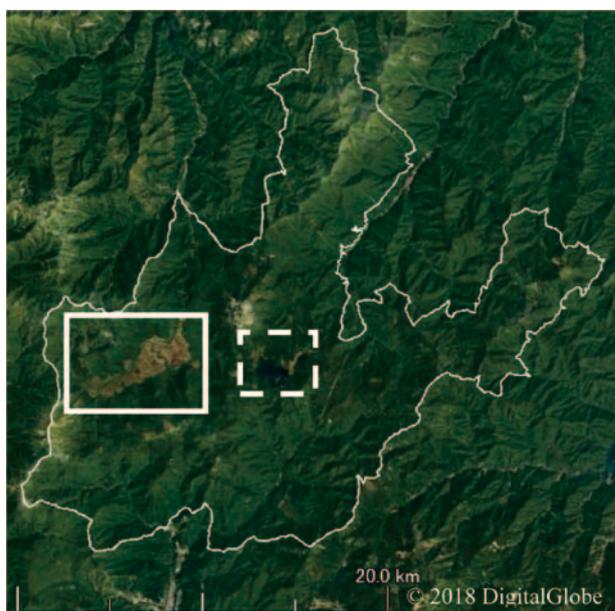


図1 研究対象地

細線は尾瀬国立公園。太実線に尾瀬ヶ原、太破線に尾瀬沼がそれぞれ含まれる。

2.2 衛星画像

アメリカ地質調査所 (USGS) の運用する Landsat8 衛星に搭載されたOLIセンサーにより観測された

2014年 (88シーン)、2015年 (86シーン)、2016年 (94シーン) の計268シーンの衛星画像を収集した (表1)。

表1 収集した衛星画像数

観測年	シーン数
2014	88
2015	86
2016	94

OLIセンサーにより提供される画像は、8つのマルチスペクトルバンド (バンド1から7および9) と、1つのパンクロマティックバンド (バンド8) により構成されるが、解析にはバンド8を除く、計8つのマルチスペクトルバンドを用いた (表2)。また、センサーの感受特性を補正するために、入手したすべての衛星画像についてDN値 (Digital Number) から放射輝度を計算し、さらに反射率 (Top of Atmosphere Reflectance) に変換する処理をした [5]。

2.3 年別モザイク画像の作成

対象地は、年間を通して雲や積雪に覆われているため、土地被覆分類処理の前処理として、観測年ごとの衛星画像に対してモザイク処理をした。モザイク処理では、USGS (2017) [8] から提供されている Quality Assessment (QA) バンドにより、衛星画像の画素ごとに雲や雪氷の領域を除去し、衛星画像に残った領域を重ね合わせることで、観測年ごとのモザイク画像を作成した。具体的には、QAバンドの各画素の値を参照し、欠損値、雲、雲による影、雪氷フラグのあるピクセルをすべて除去した。重ね合わせ処理では、雲や雪氷領域が除去された1月か

ら12月までの衛星画像を時系列順に画素ごとに抽出し、最後に出現したデータをその画素のデータとして採用した。また、いずれの年も、秋季から春季にかけては雲や積雪に覆われており、解析に用いることができた時期は、実質的には夏季に観測された一部のデータのみであった。

2.4 相観植生図の作成

2.4.1 分類に用いた手法と特徴量

機械学習の一つであり、近年、リモートセンシング分野で頻繁に用いられてきているランダムフォレストを用いて [9]、観測年ごとのモザイク画像から相観植生図を作成した。分類処理には、8つのマルチスペクトルバンドの反射率に加えて、反射率から計算した正規化植生指数、拡張植生指数、正規化都市化指数、正規化水指数、正規化土壌指数を用いた (表3)。

2.4.2 グランドトゥールース

相観植生図に用いる分類クラスは、環境省植生図 (1/25,000植生図GISデータ) をもとに計8クラス (広葉樹林、針葉樹林、湿原低木 (ツルコケモモ・ミズゴケクラス)、湿原草地 (ヌマガヤオーダー、ヨシクラス)、低木・草地 (雪田草原、蛇紋岩地植生、コケモモ・ハイマツ群集)、水域、市街地、裸地) とした。環境省植生図における尾瀬国立公園の北部の一部は、未整備領域となっている (図2-a)。グランドトゥールースとして、2017年9月4日から6日にかけて実施した尾瀬ヶ原の現地調査に基づく30ポイントのデータを用いた。さらに、解析対象全体を網羅するために、環境省植生図を前述の8クラスに再分類した上で無作為に抽出した10,000ポイントのデータをグランドトゥールースに加えた (図2-b)。また、機械学習に

表2 Landsat8/OLI の波長帯および空間分解能

バンド	波長帯 (μm)	空間分解能 (m)
Band 1 - Ultra Blue	0.435 - 0.451	30
Band 2 - Blue	0.452 - 0.512	30
Band 3 - Green	0.533 - 0.590	30
Band 4 - Red	0.636 - 0.673	30
Band 5 - Near Infrared (NIR)	0.851 - 0.879	30
Band 6 - Shortwave Infrared (SWIR) 1	1.566 - 1.651	30
Band 7 - Shortwave Infrared (SWIR) 2	2.107 - 2.294	30
Band 8 - Panchromatic	0.503 - 0.676	15
Band 9 - Cirrus	1.363 - 1.384	30

表3 解析に用いた特徴量と略称

特徴量	式	参考
正規化植生指数 (NDVI)	$NDVI = \frac{NIR - R}{NIR + R}$	Rouse Jr et al., 1974[10]
拡張植生指数 (EVI)	$EVI = 2.5 \times \frac{NIR - R}{(NIR + 6 \times R - 7.5 \times B + 1)}$	Huete et al., 2002[11]
正規化都市化指数 (NDBI)	$NDBI = \frac{NIR - SWIR1}{NIR + SWIR1}$	Zha et al., 2003[12]
正規化水指数 (NDWI)	$NDWI = \frac{R - SWIR1}{R + SWIR1}$	Mcfeeters, 1996[13]
正規化土壌指数 (NDSI)	$NDSI = \frac{SWIR1 - NIR}{SWIR1 + NIR}$	Rogers and Kearney, 2004[14]

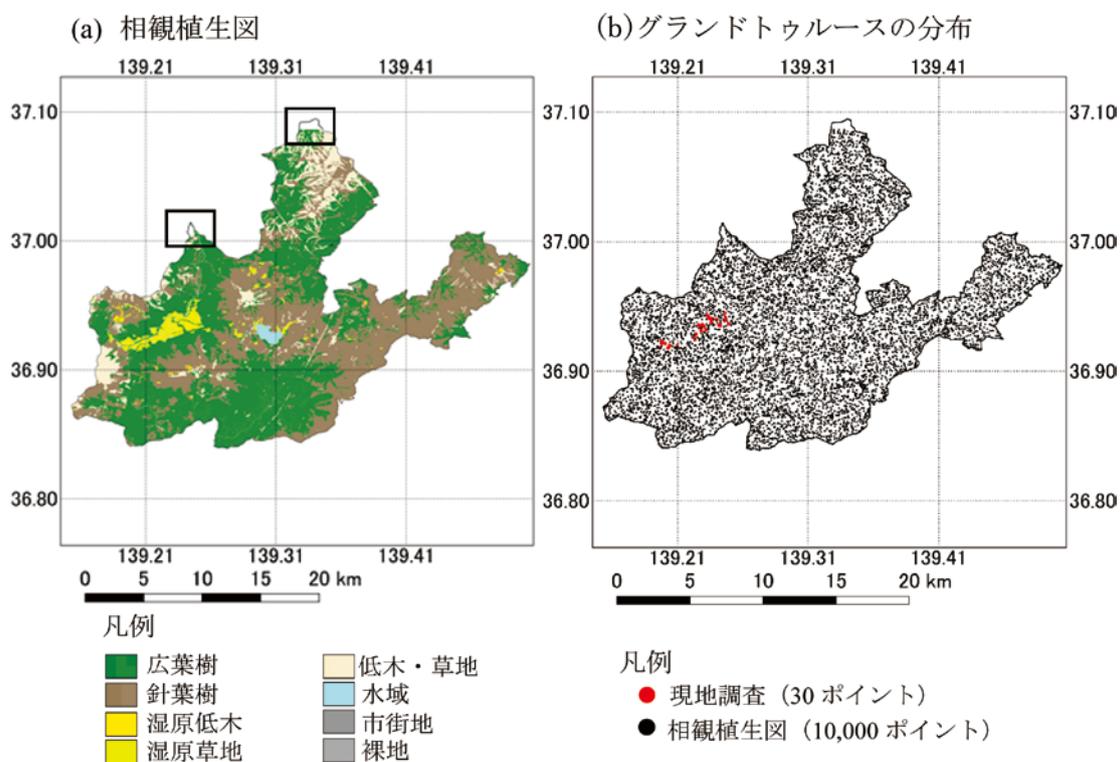


図2 環境省植生図をもとにした相観植生図とグラントゥールースの分布

(a) の実線には環境省植生図における未整備領域が含まれる。(b) には現地調査に基づく30ポイントのデータに加え、相観植生図から無作為に抽出した10,000ポイントのデータが含まれる。

用いるデータセットにおいて、各クラスが出現する割合が不均衡である場合は、一般的には、出現が少ないクラスを無視して解析が行われ[15][16]、分類精度が低下することが報告されている[17]。本研究では、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 (SMOTE; [18]) を適応し、各クラスが出現する割合を均一にした。最終的には、グラントゥールースは、11,050ポイントのデー

タとして整備し、トレーニングデータとして7,650ポイント、精度検証用データとして3,400ポイントを土地被覆分類処理に用いた。

3. 結 果

3.1 モザイク画像

雲と積雪を除去した画像を観測年ごとにモザイク処理したことで、対象地のほぼすべての範囲におい

て反射率を取得可能な観測年ごとのモザイク画像を作成できた(図3-a, b, c)。一方で、雲によって発生した影は画像上に残り、影が濃い場所では反射率の取得が困難であった。

3.2 土地被覆分類処理による相観植生図の作成結果と分類精度

土地被覆分類によって得られた相観植生図は、すべての年で非常に高い全体精度とカッパ係数が示さ

れ、それぞれ、2014年(全体精度=0.947、カッパ係数=0.940)、2015年(全体精度=0.955、カッパ係数=0.948)、2016年(全体精度=0.970、カッパ係数=0.966)であった(表4)。さらに、相観植生図の作成結果においても良好に分類されており、各クラスの分布は真値である環境省植生図と類似した位置に示されていた(図4-a, b, c, d)。また、各年の相観植生図では、環境省植生図において未整備であった領域

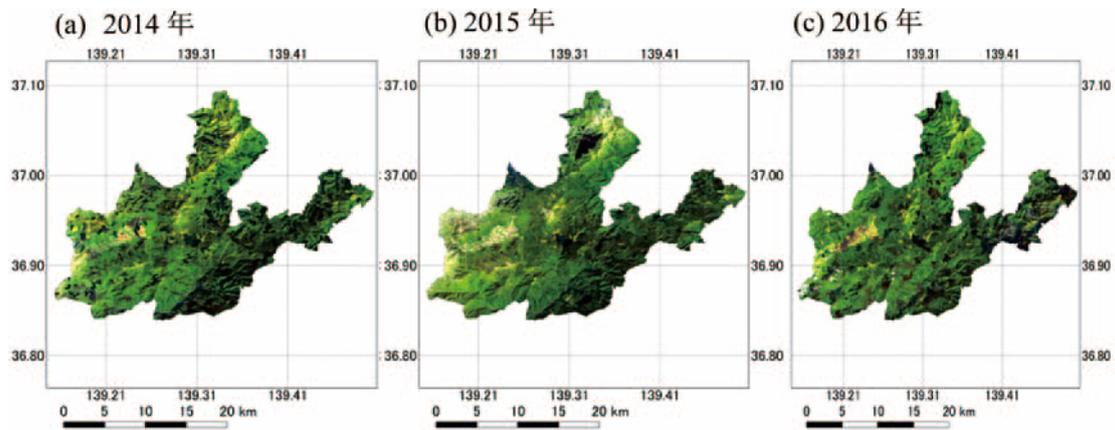


図3 観測年ごとのモザイク画像(トゥルーカラー)

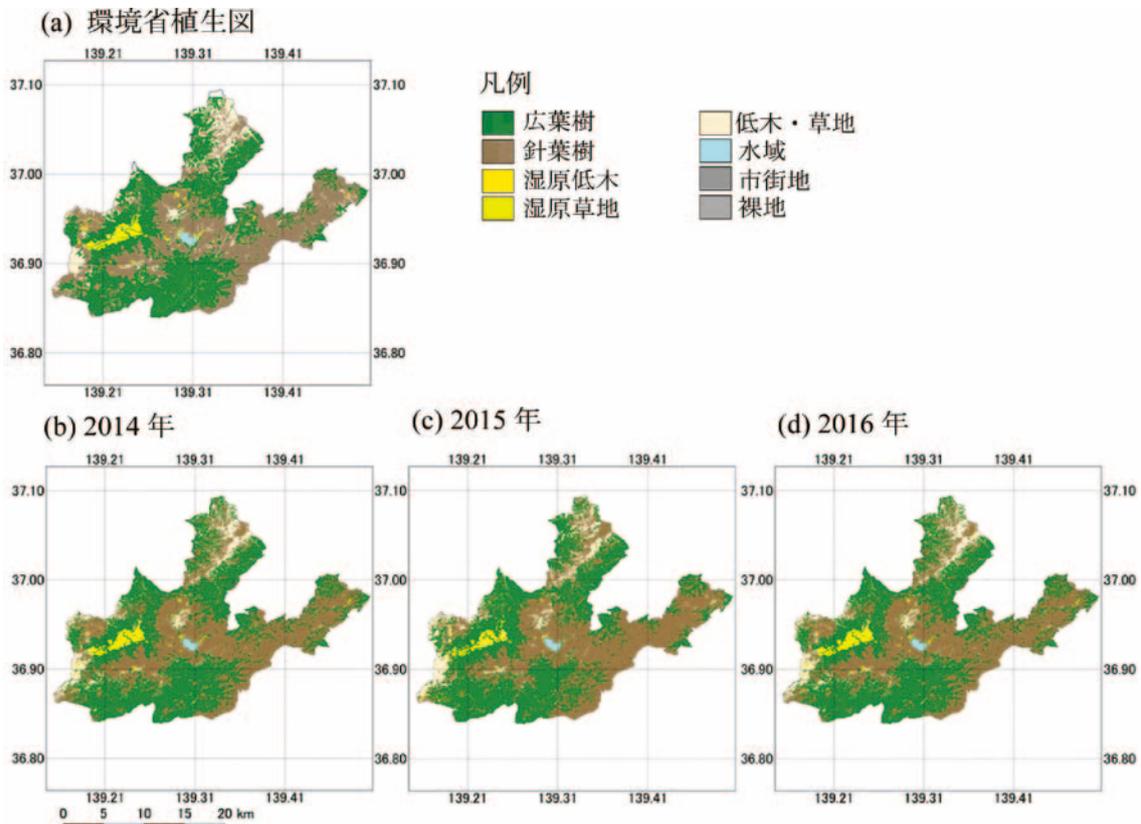


図4 環境省植生図と土地被覆分類による相観植生図

表4 観測年ごとの全体精度とカッパ係数の比較

	2014年	2015年	2016年
全体精度	0.947	0.955	0.970
カッパ係数	0.940	0.948	0.966

に、データが補完されていた。

すべての年で、広葉樹と針葉樹クラスを除くクラスは全体精度が0.9以上と正確に分類できたが、広葉樹と針葉樹クラスは互いに誤分類が発生したため、全体精度は0.8程度だった(表5、6、7)。また、広葉樹および針葉樹クラスは、低木・草地と誤分類が発生していた。

さらに、尾瀬ヶ原周辺の拡大図(図5-a, b, c, d)と尾瀬沼周辺の拡大図(図6-a, b, c, d)には、分類精度表と同様の傾向が認められた。2014年は、他の観測年と比べ誤分類が発生していた領域が多く確認

できた。具体的には、尾瀬ヶ原周辺では影状の誤分類が確認された一方(図5-b)、尾瀬沼周辺では湿地草地(真値)と低木・草地を誤分類した領域があり、当該領域のグランドトゥルース数は少なかったことが確認できた(図6-a, b)。2015年と2016年については各クラスの分布を概ね良好に表現できた一方で、尾瀬沼周辺では真値の広葉樹に対して、2015年と2016年ともに針葉樹に誤分類された領域が確認された(図5-c, d)。また、2014年から2016年のすべての年において、低木・草地(真値)を針葉樹や広葉樹と誤分類した領域が認められた(図6-b, c, d)。

3.3 土地被覆クラスの年変化

土地被覆クラス面積の割合を計算した結果、最も年変化が大きいクラスは、広葉樹クラスであり、2014年から2015年にかけては1.6%減少し、2015年から2016年にかけては2.6%増加した(図7)。次い

表5 2014年の分類精度表

2014年 予測\真値	広葉樹	針葉樹	湿地低木	湿地草地	低木・草地	水域	市街地	裸地	ユーザ 精度
広葉樹	324	63	0	0	0	0	0	0	0.84
針葉樹	80	349	0	0	0	0	0	0	0.81
湿地低木	1	0	425	0	0	0	0	0	1.00
湿地草地	1	2	0	425	0	0	0	0	0.99
低木・草地	18	11	0	0	425	0	0	0	0.94
水域	0	0	0	0	0	425	0	0	1.00
市街地	0	0	0	0	0	0	425	0	1.00
裸地	1	0	0	0	0	0	0	425	0.99
プロデューサ 精度	0.76	0.82	1.00	1.00	1.00	1.00	1.00	1.00	$N=3,400$

表6 2015年の分類精度表

2015年 予測\真値	広葉樹	針葉樹	湿地低木	湿地草地	低木・草地	水域	市街地	裸地	ユーザ 精度
広葉樹	321	38	0	0	0	0	0	0	0.89
針葉樹	81	377	0	0	0	0	0	0	0.82
湿地低木	0	0	425	0	0	0	0	0	1.00
湿地草地	2	0	0	425	0	0	0	0	1.00
低木・草地	21	10	0	0	425	0	0	0	0.93
水域	0	0	0	0	0	425	0	0	1.00
市街地	0	0	0	0	0	0	425	0	1.00
裸地	0	0	0	0	0	0	0	425	1.00
プロデューサ 精度	0.76	0.89	1.00	1.00	1.00	1.00	1.00	1.00	$N=3,400$

表7 2016年の分類精度表

2016年 予測\真値	広葉樹	針葉樹	湿地低木	湿地草地	低木・草地	水域	市街地	裸地	ユーザ 精度
広葉樹	329	3	0	0	0	0	0	0	0.99
針葉樹	73	419	0	0	0	0	0	0	0.85
湿地低木	0	0	424	0	0	0	0	0	1.00
湿地草地	0	0	0	424	0	0	0	0	1.00
低木・草地	23	2	0	0	424	0	0	0	0.94
水域	0	0	0	0	0	424	0	0	1.00
市街地	0	0	0	0	0	0	424	0	1.00
裸地	0	0	0	0	0	0	0	424	1.00
プロデューサ 精度	0.77	0.99	1.00	1.00	1.00	1.00	1.00	1.00	$N = 3,393$

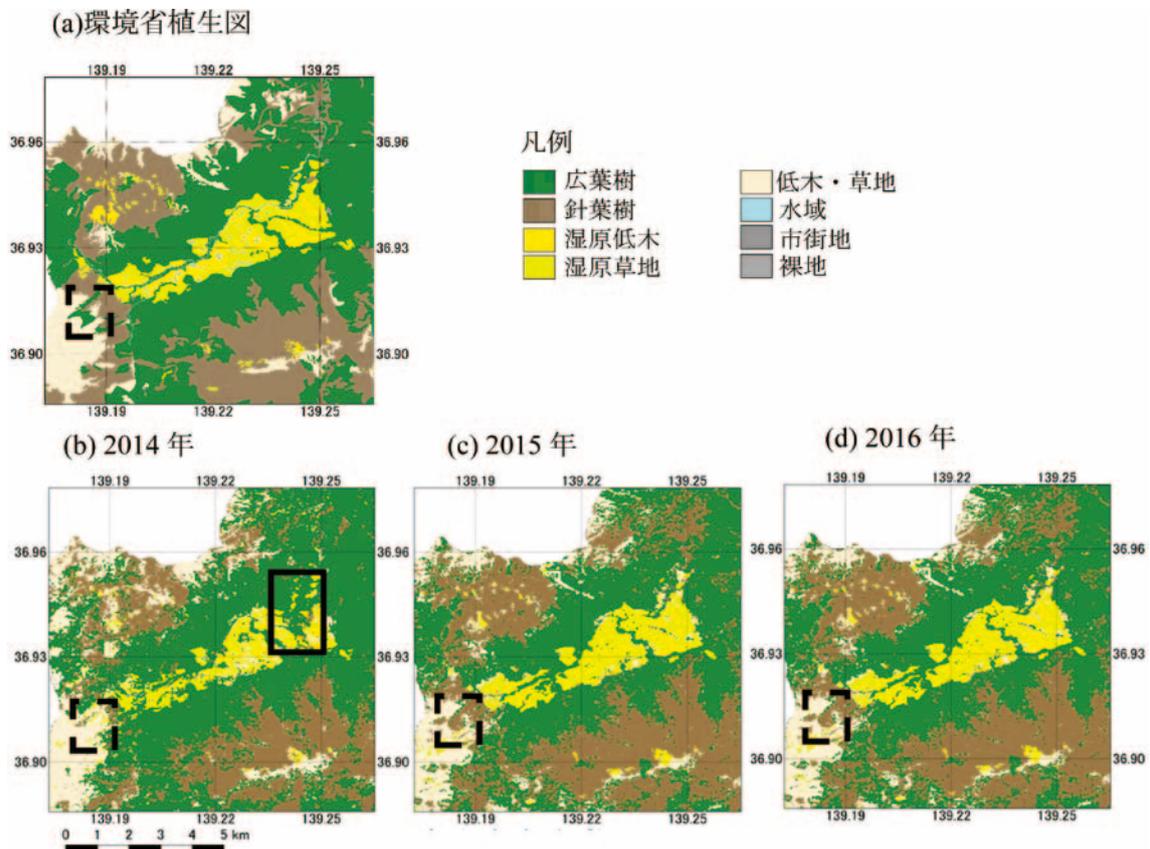


図5 尾瀬ヶ原周辺の拡大図

実線には影の影響により誤分類が生じた領域が含まれる。破線には真値に対して年ごとに異なる分類結果となった領域が含まれる。

で、年変化が大きいクラスは、草地・低木クラスであり、2014年から2015年にかけては0.8%増加し、2015年から2016年にかけては1.4%減少していた。その他のクラスは、いずれも約0.01%から1.0%以内の増減であった。また、表5、6、7のユーザ精度

をもとに、各クラスの分類誤差を求めると、2016年の広葉樹を除く広葉樹、針葉樹、低木・草地の3つのクラスは、各年で±6%~19%の幅があり、その他のクラスは、±1%の幅があった。

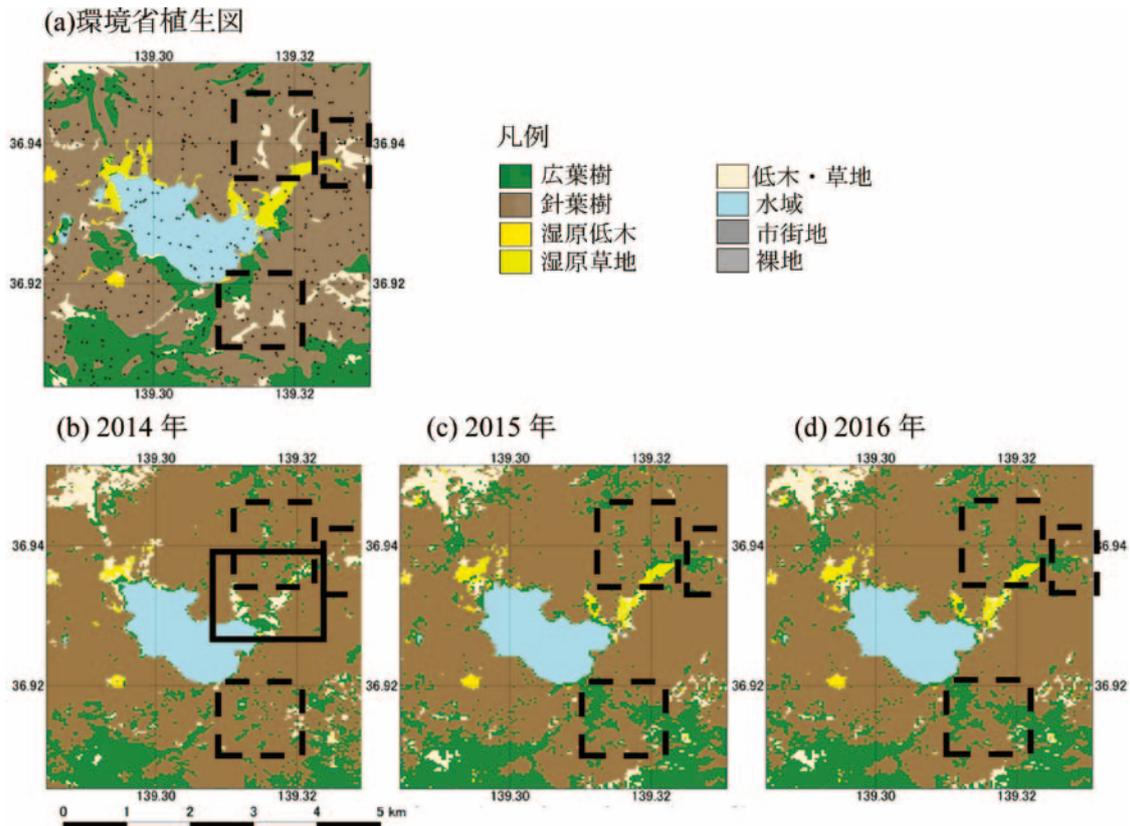


図6 尾瀬沼周辺の拡大図

(a) の黒点はグラントゥルースデータ。実線には影の影響により誤分類が生じた領域が含まれる。破線には真値に対して年ごとに異なる分類結果となった領域が含まれる。

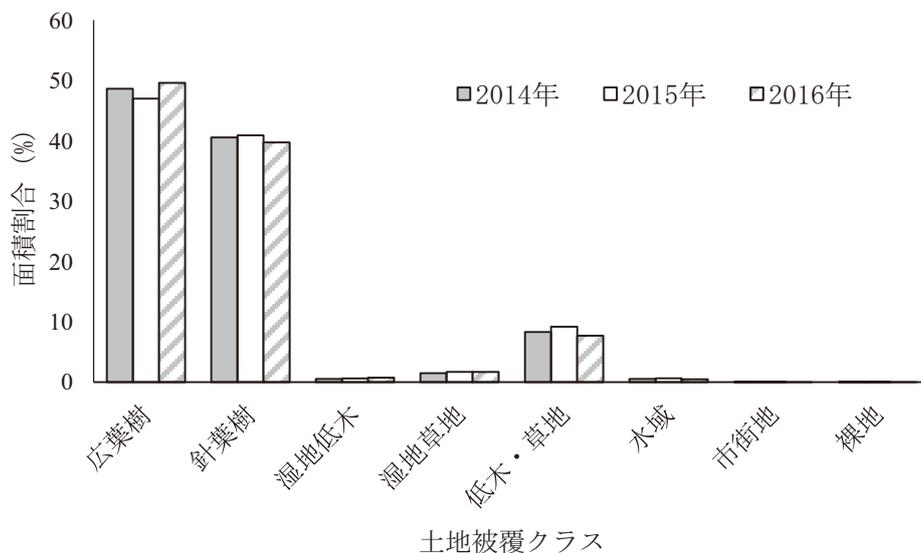


図7 観測年ごとのクラス別の土地被覆割合

4. 考察

4.1 分類精度を高めた要因

本研究では、すべての年において、全体精度0.9以

上と非常に高い分類精度をもつ相観植生図を作成することができた(表4)。また、環境省植生図において未整備であった領域における土地被覆についても補完することができた(図4-a, b, c, d)。分類精度の

向上に寄与した要因としては、まず、雲や積雪の影響を除去したモザイク画像を整備できたことにより、広範囲にわたって地表面の反射率を取得できたことがあげられる(図3-a, b, c)。また、衛星画像を用いた教師付き分類の精度を高めるためには、多量のランドトゥールズを整備することや[6]、機械学習に用いるデータセットにおいて各クラスの出現する割合を一定にすることが有効であるとされる[7]。今回の相観植生図の分類精度の高さは、対象地において十分なデータ整備ができたことを示唆している。

4.2 複数年にわたる衛星画像を用いたモザイク処理実施の可能性

尾瀬国立公園を含む研究対象地における土地被覆の経年変化が不明であったことから、本研究のモザイク処理では年度ごとに衛星画像を処理し、年別の1枚ずつのモザイク画像を作成した。土地被覆面積を解析したところ、広葉樹を除く土地被覆クラスの面積割合の変化は約0.01%から1.0%以内の増減を示し、最も変化があった広葉樹クラスでも1.6%から2.6%の増減であった(図7)。これらの面積割合の増減は、それぞれの分類クラスにおける分類誤差の範囲内だと考えられた(表5、6、7)。この結果から、2014年から2016年の間、当該地域の土地被覆には大きな変化がないことが示唆された。

4.3 クラス間の分類精度向上への課題

広葉樹と針葉樹の相互的な誤分類が発生していたことや、低木・草地(真値)を広葉樹や針葉樹と誤分類していた領域が確認されたことから(表5、6、7、図5-a, b, c, d、6-a, b, c, d)、広葉樹、針葉樹、低木・草地の分類には課題があることが示された。また、年ごとの分類結果から、クラスの分布が一致しない部分の確認された。これは、広葉樹、針葉樹、低木・草地クラスのユーザ精度がそれぞれ0.8~0.9程度であったことに起因すると考えられた(表5、6、7)。衛星画像を用いた植生の分類手法に関するこれまでの研究によって、植生の季節変化を時系列で捉えた解析が有効であることが報告されている[19][20]。本研究では複数時期の画像を1枚にまとめたために植生の季節変化の情報が得られず、各クラス間で誤分類が発生したと考えられた。

5. まとめ

尾瀬国立公園を対象とした相観植生図の作成にお

いて、1年間にわたる衛星画像を用いて雲や影の除去したモザイク画像を作成すること、さらに、多量のランドトゥールズを用いた機械学習により解析することが有効であった。また、湿原生態系の特徴を表す分類クラスとしては、湿原低木、湿原草地、低木・草地の3クラスに分類できることが明らかとなった。今後は、本研究の解析結果の検証のために現地調査を実施するとともに、相観植生図の高精度化に向けたデータ整備と解析手法の検討を実施したい。

謝 辞

この調査研究は、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行われた。基礎調査部会の鈴木邦雄部会長には、調査全体にわたってご教示いただき、また、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】

- [1] 坂口豊：尾瀬ヶ原の自然史，中公新書(1989)。
- [2] 尾瀬の自然を守る会：尾瀬自然ハンドブック改訂版，自由国民社(1996)。
- [3] 尾瀬保護財団：平成28年度版尾瀬保護レポート，入手先〈<https://www.oze-fnd.or.jp/wp4/wp-content/uploads/2015/07/da029d0111bfeb23474c9b8ae5aff63f.pdf>〉(参照2018-02-20)。
- [4] 尾瀬国立公園協議会：第14回 尾瀬国立公園協議会会議資料，入手先〈<https://www.env.go.jp/park/oze/data/index.html>〉(参照2018-02-22)。
- [5] USGS: Landsat 8 (L8) Data Users Handbook. USGS (2016)。
- [6] Sharma, R. C., Keitarou, H. and Hidetake, H.: A Machine Learning and Cross-Validation Approach for the Discrimination of Vegetation Physiognomic Types Using Satellite Based Multispectral and Multitemporal Data, *Scientifica*, Vol.2017, pp.1-8 (2017)。
- [7] Waldner, F., Jacques, D. C. and Löw, F: The impact of training class proportions on binary cropland classification, *Remote Sensing Letters*, Vol.8, pp.1123-1132 (2017)。
- [8] USGS: Landsat 8 Pre-Collection Quality Assessment Band, available from 〈<https://landsat.usgs.gov/qualityband>〉(accessed 2018-02-22)。
- [9] Breiman, L: Random forests, *Machine learning*, Vol.45, pp.5-32 (2001)。

- [10] Rouse Jr, J., Haas, R. H., Schell, J. A. and Deering, D. W.: Monitoring vegetation systems in the Great Plains with ERTS, *NASA special publication*, Vol.351, pp.309 (1974).
- [11] Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X. and Ferreira, L. G.: Overview of the radiometric and biophysical performance of the MODIS vegetation indices, *Remote Sensing of Environment*, Vol.83, pp.195-213 (2002).
- [12] Zha, Y., Gao, J. and NI, S.: Use of normalized difference built-up index in automatically mapping urban areas from TM imagery, *International Journal of Remote Sensing*, Vol.24, pp.583-594 (2003).
- [13] Mcfeeters, S. K.: The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features, *International Journal of Remote Sensing*, Vol.17, pp.1425-1432 (1996).
- [14] Rogers, A. S. and Kearney, M. S.: Reducing signature variability in unmixing coastal marsh Thematic Mapper scenes using spectral indices, *International Journal of Remote Sensing*, Vol.25, pp.2317-2335 (2004).
- [15] Japkowi, N. and Shaju, S.: The Class Imbalance Problem: A Systematic Study, *Intelligent Data Analysis*, Vol.6(5), pp.203-231 (2002).
- [16] Visa, S. and Ralescu, A.: Issues in mining imbalanced data sets—a review paper, *Proc. the sixteen midwest artificial intelligence and cognitive science conference*, pp.67-73 (2005).
- [17] Prati, R. C., Batista, G. E. A. P. A. and Silva, D. F.: Class imbalance revisited: a new experimental setup to assess the performance of treatment methods, *Knowledge and Information Systems*, Vol.45, pp.247-270 (2015).
- [18] Chawla, N. V., Bowyer, K. W., Hall, L. O. and Kegelmeyer, W. P.: SMOTE: Synthetic minority over-sampling technique, *Journal of Artificial Intelligence Research*, Vol.16, pp.321-357 (2002).
- [19] Melaas, E. K., Friedl, M. A. and Zhu, Z.: Detecting interannual variation in deciduous broadleaf forest phenology using Landsat TM/ETM+ data, *Remote Sensing of Environment*, Vol.132, pp.176-185 (2013).
- [20] Gamon, J. A., Huemmrich, K. F., Stone, R. S. and Tweedie, C. E.: Spatial and temporal variation in primary productivity (NDVI) of coastal Alaskan tundra: Decreased vegetation growth following earlier snowmelt, *Remote Sensing of Environment*, Vol.129, pp.144-153 (2013).