

オブジェクトベース画像分析による森林タイプ分類における分類手法ならびに特徴量選択に関する検討

中川恭兵¹・村上拓彦^{1*}

(平成24年7月6日受付)

要 約

現在、リモートセンシングデータを使用した迅速な相観植生図の作成が期待されている。本論では SPOT5 データを使用し、佐渡地域における森林タイプ分類を試みた。画像分類にはオブジェクトベース画像分類を用い、NN (Nearest Neighbor) 法と CART (Classification and Regression Trees) 法の2種類の分類手法や、初期段階で分類に組込む特徴量を変えた分類結果を比較した。本研究では、初期段階で組込む特徴量の少ない NN 法が最も良い分類精度を示した。NN 法での、初期段階で組込む特徴量の数の違いによる分類結果を比較すると、特徴量を多く組込んだ方が分類精度は低くなっており、特徴量の多さが分類精度の向上に必ずしも結び付くわけではないということが分かった。一方、CART 法では、初期段階で組込む特徴量の数を変化させても、選択される特徴量が限定されており、両者に差は認められなかった。これらの結果から、分類手法に応じて、初期段階で分類に組込む特徴量の各クラスの分離に対する有効性を精査し、事前に選別した方がいい場合があることが確認された。

新大農研報, 65(1):57-65, 2012

キーワード：オブジェクトベース画像分類、SPOT5、森林タイプ分類、NN 法、CART 法

森林分野、自然環境分野では、リモートセンシングデータを用いた植生図の作成に関する研究が数多く行われている（例えば、渡辺, 2006；鎌形ら, 2006；長澤, 2006；伊藤ら, 2007；Xie *et al.*, 2008）。現在、日本の植生分布を示した情報として、環境省の第6・7回自然環境保全基礎調査植生調査の結果である2万5千分の1で作成された現存植生図を利用することができる。しかし、作成に要する作業量の膨大さから、作業完了までに長い年月を要し、自然環境の基盤情報としては期待にそぐわないことが指摘されている（日置, 2007）。マツ枯れのようなマツの大量枯損を引き起こす樹病や自然災害等による植生の変化をこの現存植生図から即時に捉えることは困難である。植生図は森林分野だけでなく、野生動植物の生息域の推定等の自然環境分野でも重要な情報源であり、利用価値は高い。

現在、リモートセンシングデータを用いた研究に関する知識の蓄積や技術の革新が進む中で、画像分類手法の1つとして、高分解能衛星データに対するオブジェクトベース画像分類が注目されている（例えば、小阪ら, 2007；Blaschke, 2010）。従来のピクセルベース画像分類では、画像を構成する画素1つを分類の最小単位としていたのに対し、オブジェクトベース画像分類では、空間的に隣接する比較的均質な画素のまとまり（オブジェクト）を分類の最小単位としている。オブジェクトベースの利点はオブジェクト単位で分類結果が得られるため、視覚的に林相を認識しやすいことに加え、分類に使用できる特徴量が従来のピクセルベース画像分類と比較して豊富なことが挙げられる。オブジェクトがピクセルの集合体であることから、オブジェクト単位での平均値や標準偏差等の統計量、またオブジェクト自身の形状やテクスチャに関する指数、隣接するオブジェクトやオブジェクトサイズの異なる上下位階層のオブジェクトとの関係性のようにオブジェクトを特徴付ける定量的、定性的条件が豊富に存在する（村上, 2010）。本研究では、このオブジェクトベース画像分類による、リモートセンシングデー

タを用いた対象地域における森林タイプ分類の実施を目的とした。本論では特に分類手法や分類に使用する特徴量の違いから得られる分類結果の違いを考察した。

研究対象地

研究対象地は、新潟県佐渡地域である。佐渡地域は、面積855.26km²、海岸線延長280.6kmと日本海側最大級の離島であり、北には標高1,172mの金北山を最高峰とする大佐渡山地、南には標高645mの大地山を中心とした小佐渡丘陵を擁し、これらに挟まれる形で国仲平野が広がっている。佐渡地域の74%の面積が森林に覆われており、主要樹種はコナラ、ミズナラをはじめとする広葉樹が全体の70%を占め、針葉樹はスギ、ヒノキアスナロ、アカマツ、クロマツから成り、竹林も分布している。

方法

使用データ

本論では SPOT5 データを使用した。SPOT5 データは、マルチスペクトル画像（空間分解能10m）と、パンクロマチック画像（空間分解能2.5m）で構成されている。撮影時期は、マルチスペクトル、パンクロマチックともに2007年6月3日に撮影されたものである。光学衛星 SPOT5 の諸元を表1に示す。マルチスペクトル画像は、可視緑色域（GREEN）、可視赤色域（RED）、近赤外域（NIR）、短波長赤外域（SWIR）の4バンド構成となっている。

その他のデータは、DEM (Digital Elevation Model：数値標高モデル)として国土地理院が提供している数値地図10mメッシュ（標高）を用いた。また、水土里ネットより提供を受けた簡易オルソフォト（2006年撮影、空間分解能0.25m）を精度

¹ 新潟大学大学院自然科学研究科

* 代表著者：muratac@agr.niigata-u.ac.jp

検証のために使用した。

衛星画像の前処理

衛星画像の前処理として、パンシャープン画像の作成、オル

表1. SPOT5衛星の諸元

国籍	フランス	
運用	2002～	
センサ名	HRG	
観測波長帯	可視緑色域	0.50-0.59 μ m
	可視赤色域	0.61-0.68 μ m
	近赤外域	0.78-0.89 μ m
	短波長赤外域	1.58-1.75 μ m
	パンクロマティック	0.48-0.71 μ m
地上分解能	マルチスペクトル	10m (短波長赤外域は20m)
	パンクロマティック	2.5m
観測幅	60km	

ソ幾何補正、地形効果補正を行った。パンシャープン画像は、マルチスペクトル画像とパンクロマチック画像を掛け合わせることで、4バンド構成を有しながら分解能が2.5mの画像となる(図1)。この処理は、ERDAS IMAGINE 9.3 (erdas社, 米国)のHPF Resolution Mergeで実行した。オルソ幾何補正とは、センサの姿勢や向き、内部誤差、また地形の起伏による歪み等の幾何学的な歪みを取り除く処理である。地形効果補正は、地形の起伏や太陽の高度の影響で画像に生じた陰影(地形効果)を除去、軽減する処理である。本研究では、坂本ら(2009)が提案した二分割回帰法(DPR: Dual Partitioning Regression)を用いた。

指数データの作成

指数データとしてNDVI (Normalized Difference Vegetation Index)、SWVI (Short Wave Vegetation Index)、NDWI (Normalized Difference Water Index)をバンド間演算により作成した。NDVIは植物の葉に含まれるクロロフィルが、可視赤色域の波長帯を強く吸収し、葉の細胞構造が近赤外域の波長帯を強く反射するという性質を利用した植生指数である(松英, 2010)。SWVIは、NDVIの可視赤色域を短波長赤外域に置き換えたもので、焼け地の特徴等を他の指標よりも強く示す指数



図1. パンシャープン画像の作成。左上:マルチスペクトル画像(空間分解能10m、4バンド)、右上:パンクロマチック画像(空間分解能2.5m、単一バンド)、下:パンシャープン画像(色調を有しかつ空間分解能が2.5m)。

として報告されている(例えば, Zhang *et al.*, 2005)。NDVIは、地表面の水分状況を定量的に表すとされる短波長赤外域を利用した指標で、水分に関する指数として有効とされている(竹内・安岡, 2004)。以下に、それぞれの指数の算出式を示す。

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (NIR: \text{近赤外域}, RED: \text{可視赤色域}) \quad (1)$$

$$SWVI = \frac{NIR - SWIR}{NIR + SWIR} \quad (SWIR: \text{短波長赤外域}) \quad (2)$$

$$NDWI = \frac{RED - SWIR}{RED + SWIR} \quad (3)$$

尾根線からの距離データの作成

櫻井ら(2009)は、衛星画像のスペクトル情報に加え、地形情報を森林タイプ分類に加えることで、精度の向上を図っている。本研究では、DEMをもとに、尾根線からの距離を示す画像を作成した。DEMに-1を乗じ、ローパスフィルタを実行した後に、水文解析と同様の手順で、流向、累積流量の順に算出し、累積流量に対して閾値を設定することで尾根線を再現した。尾根線を作成後、近隣の尾根線からの距離を示すデータを作成した。

画像分類

画像分類は、GREEN、RED、NIR、SWIRの4つのスペクトル画像に加え、NDVI、SWVI、NDWIの指数データ、さらに標高データであるDEMと尾根線からの距離データを合成し

た、計9レイヤ構成のデータセットに対して行った。植生部のみを画像分類するため、NDVIで閾値を設定してマスク処理を実行した。

画像分類はオブジェクトベース画像分類で行った。使用ソフトは、Definiens Developer 7.0 (Definiens社, ドイツ)である。オブジェクトベース画像分類では、まずセグメンテーションを行うことによって、画素のまとまりであるオブジェクトを生成する。セグメンテーションの際にはScale、Shape、Compactnessの各パラメータを設定する。今回は、Scale:20、Shape:0.3、Compactness:0.5でセグメンテーションを実行した。分類手法には、NN法とCART法を採用した。NN法とは、特徴空間において、未分類オブジェクトと各クラスのサンプルを分布させ、特徴空間上の距離が最も近接しているサンプルのクラスに未分類オブジェクトを分類する手法である。NN法は、Definiens Developer 7.0にあるFeature Space Optimization機能を使用した。これは、各クラスのサンプルを比較し、それぞれを各クラスに分類するために、組込んだ特徴量の中から最適な特徴量を自動で選出してくれる機能である。ここで得られた結果をそのままNN法に使用することができる。CART法とは、説明変数の値を分岐条件とし、それらを組合せて、判別、予測モデルを構築する樹木モデルの1つである。CART法では、説明変数を2進分岐させ、2進木を生成する。その際、節の分岐の評価基準には尤度とジニ係数を用いている。CART法は、各クラスのサンプルの特徴量を用いて、フリーソフトR2.10.0にある関数treeを用いて行った。初期段階で分類に組込む特徴量は2パターンに分けた(表2)。1つは、全9レイヤのオブジェクト内の平均(Mean)、標準偏

表2. 初期段階で分類に組込む特徴量

特徴量の数		使用する特徴量
多数	オブジェクト内の平均 (Mean)	GREEN (可視緑色域) RED (可視赤色域) NIR (近赤外域) SWIR (短波長赤外域) NDVI SWVI NDWI DEM DIS (尾根線からの距離)
	オブジェクト内の標準偏差 (Stdd)	GREEN (可視緑色域) RED (可視赤色域) NIR (近赤外域) SWIR (短波長赤外域) NDVI SWVI NDWI DEM DIS (尾根線からの距離)
Brightness (全レイヤの合計)、Max.diff (最大値と最小値との差)		
少数	オブジェクト内の平均 (Mean)	GREEN (可視緑色域) RED (可視赤色域) NIR (近赤外域) SWIR (短波長赤外域)

差 (Std)、さらに Brightness (全レイヤの合計)、Max.diff (最大値と最小値との差) と多くの特徴量を組込んだ。もう1つは、衛星画像のオリジナルバンドである可視緑色域、可視赤色域、近赤外域、短波長赤外域のオブジェクト内の平均 (Mean) のみとした。分類項目はアカマツ、竹林、スギ、広葉樹の4クラスである。精度評価は、分類画像に対して、ランダムポイントを発生させ、簡易オルソフォトを参照データとして、各ポイントにおける真の土地被覆を確認して実行した。その結果は判定効率表としてまとめた。分類手法、分類に組込む特徴量を変えることで、分類精度の比較を行った。

結果

NN 法での多次元空間での分離度をそれぞれ図2に示す。また、CART 法での分類樹をそれぞれ図3、4に示す。実際に分類に使用した特徴量を表3にまとめている。NN 法では、特徴量を多数組込むと、12の特徴量を使用して分類を実行していた。NN 法では NIR、SWIR が共通して選択されていた。一方、CART 法では、組込む特徴量の数も異なっても、選択された

特徴量はいずれも少なく、また SWIR が共通して分類に使用されていた。NN 法、CART 法で選択された特徴量を見ると、必ず SWIR が分類に使用されていることが分かる。

分類結果を図5に示す。分類結果を見ると、NN 法で特徴量を多数組込んだものは、アカマツ、竹林が過大に分類されていた。また、CART 法は組込む特徴量の数に関係なく、分類結果も類似していた。判定効率表を表4~7に示す。判定効率表を見ると、NN 法で組込む特徴量の少ないものが最も精度の良い結果となっていた。アカマツはスギ、広葉樹との誤分類が多かった。竹林はどの分類結果でも精度が低かった。スギは User's Accuracy が高いものの、Producer's Accuracy は低かった。広葉樹は他の分類クラスよりも精度が高かった。

考察

選択された特徴量に着目すると、SWIR が必ず分類に使用されており、樹種分類に有効に働いたことが分かる。また、SWVI が NIR と SWIR から算出されることから、NIR も全ての分類に関係していたこととなる。

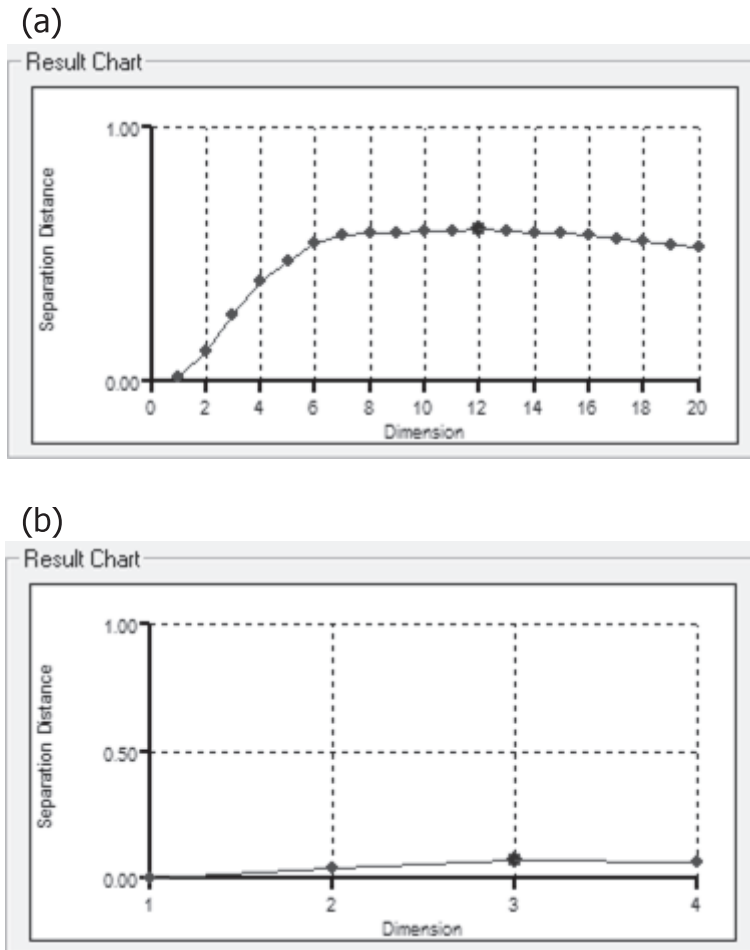


図2. NN 法での多次元空間での分離度分析。(a) 特徴量多数の場合。12の特徴量を使用することで各クラスを最も分離できることを示している。(b) 特徴量少数の場合。3つの特徴量を使用することで各クラスを最も分離できることを示している。

分類手法に着目すると、NN法では、実際に分類に使用した特徴量の数は、初期段階で分類に組込む特徴量が多数であった方が多かったが、分類精度は初期段階で分類に組込む特徴量が限定した方が良好だった。このことは、NN法では組込む特徴量を初期段階で、各クラスを分離するために必要最低限の数の

特徴量を選定しなければならないことを示している。CART法で選択された特徴量は、組込んだ特徴量の数に関係なく少数であったこと、また、SWVIの方がNIRよりもクラスの分離に有効であったと仮定するならば、選択された特徴量の違いは、初期段階で組込む特徴量の違いでしかなかった。CART法では初期段階で多くの特徴量を組込んだ方が分類に有利である可能性がある。また、オブジェクトの平均のみでもある程度の精度が得られるということが分かった。

分類結果に着目すると、アカマツのクラスはスギや広葉樹のクラスと多く誤分類を生じていた。これは、スギの若齢林の示すスペクトル特徴量がアカマツと類似していたこと、アカマツと広葉樹の混交状態にある林分では分類が困難であったことが原因であった。スギの若齢林との誤分類箇所に関しては、テクスチャ特徴量といった本研究では使用していないオブジェクトの特徴量の検討が必要である(河邑ら, 2005)。広葉樹との混交状態にあるアカマツを抽出するには、適切なオブジェクトを作成することができなかったため、オブジェクトベース画像分類では困難であった。今後は、アカマツ広葉樹混交クラスの設定や分解能のより高い衛星画像での分類、もしくはピクセルベース画像分類との併用を検討する必要がある。本来、オブジェクトベース画像分類ではオブジェクトに階層性を持たせることが可能であるが、今回使用したデータの分解能の高さと対象地の広域さから、オブジェクトサイズを決定するスケールパラメータの設定には限界があり、ピクセルレベルの詳細なオブジェクトの作成は叶わなかった。今回は6月データを使用しているが、さらに落葉期のデータ等も含めた多時期合成画像(小出, 2008)での分類も検討しなければならない。

今後、相観植生図の作成にあたり、リモートセンシングデータの利用に対する期待はさらに大きくなるだろう。樹種分類を行う際には、植生図の利用目的(例えば、求める情報の質と精度)、リモートセンシングデータの種類(例えば、観測する波長帯や分解能の高さ)や対象地の林況(例えば、純林や混交林)、分類に使用する特徴量や分類手法を各地域で検証し、実用に応じた解析、解析結果の提示を検討していく必要がある。

まとめ

SPOT5データを使用し、オブジェクトベース画像分析での森林タイプ分類を行った。SPOT5データの有する短波長赤外域、近赤外域の情報が分類に有効であった。また、使用する分類手法、初期段階での特徴量の数により、分類精度が異なることを示した。分類手法によっては、初期段階での特徴量の選別が解析者に要求される。

課題は、特徴量の選別と精度向上のための分類手法の検討が

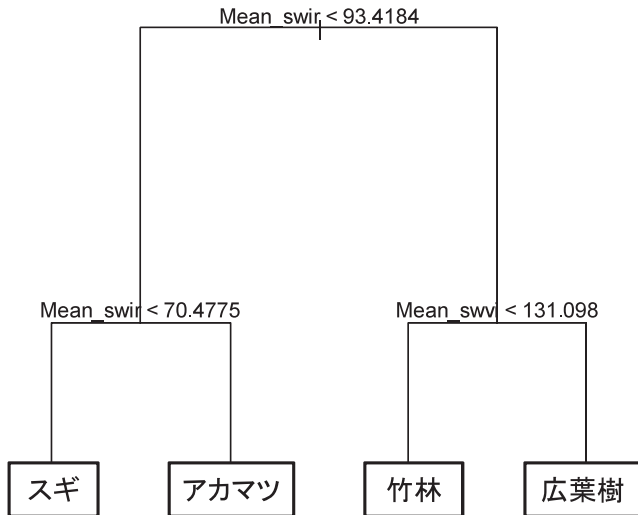


図3. 特徴量多数のCARTの分類樹。

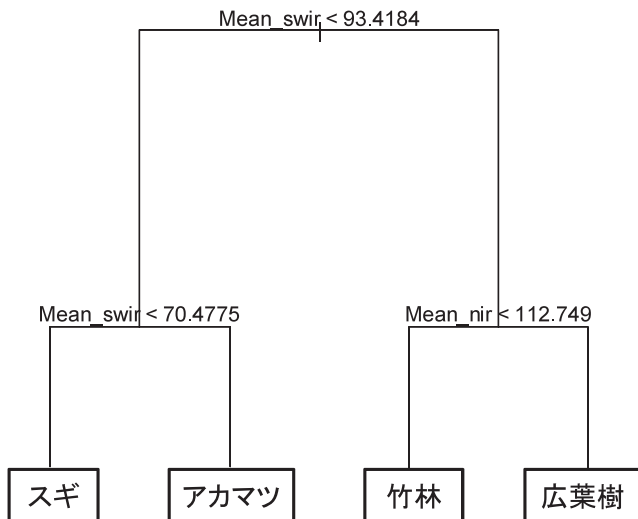


図4. 特徴量少数のCARTの分類樹。

表3. 実際に分類に使用した特徴量

分類手法	特徴量の数	選択された特徴量
NN	多数	Mean : NIR, SWIR, NDWI, DEM, DIS Stdd : RED, NIR, SWIR, NDWI, DEM, DIS Max_diff
NN	少数	Mean : RED, NIR, SWIR
CART	多数	Mean : SWIR, SWVI
CART	少数	Mean : NIR, SWIR

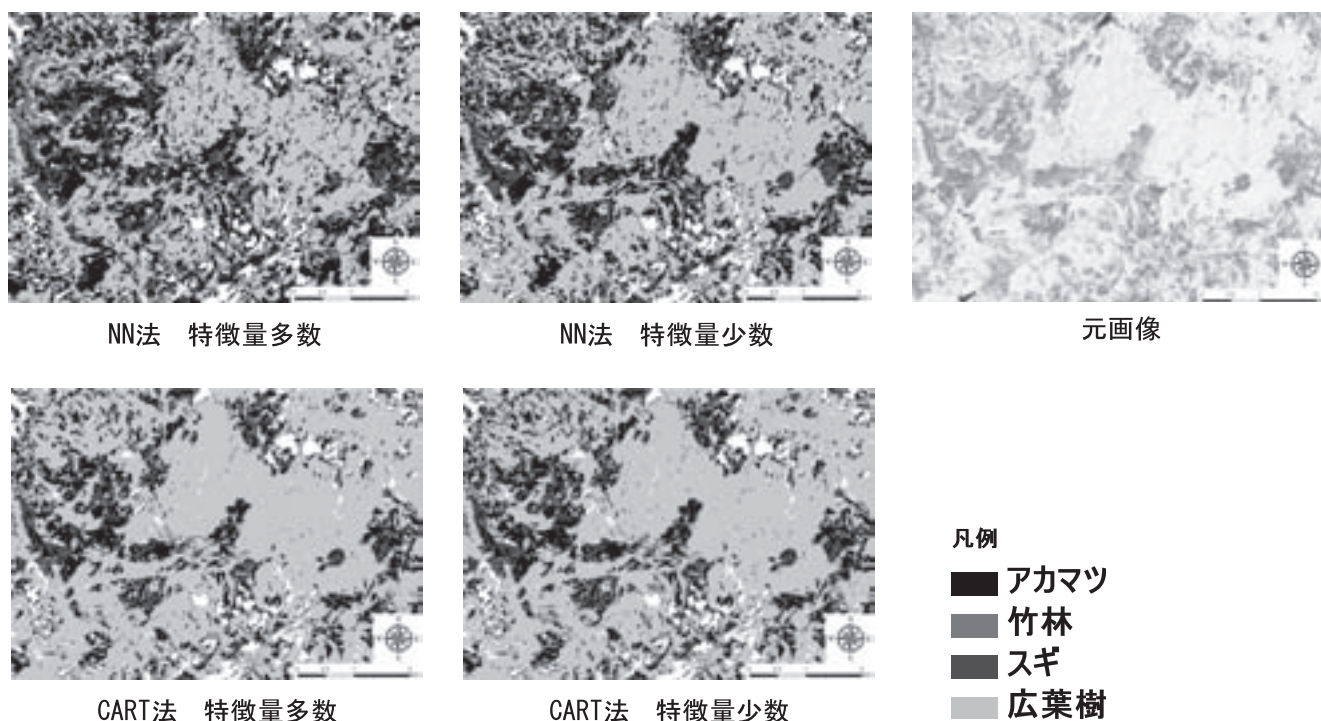


図 5. 分類結果。

表 4. 判定効率表 (NN 法、特徴量多数)

分類クラス	参照クラス				計	User's Accuracy
	アカマツ	竹林	スギ	広葉樹		
アカマツ	54	6	37	87	184	0.29
竹林	31	12	22	87	152	0.08
スギ	9	0	39	7	55	0.71
広葉樹	23	4	7	284	318	0.89
計	117	22	105	465	709	
Producer's Accuracy	0.46	0.55	0.37	0.61		
全体精度	0.55					
Kappa 係数	0.30					

表 5. 判定効率表 (NN 法、特徴量少数)

分類クラス	参照クラス				計	User's Accuracy
	アカマツ	竹林	スギ	広葉樹		
アカマツ	65	4	50	73	192	0.34
竹林	9	7	1	10	27	0.26
スギ	6	0	41	0	47	0.87
広葉樹	37	11	13	382	443	0.86
計	117	22	105	465	709	
Producer's Accuracy	0.56	0.32	0.39	0.82		
全体精度	0.70					
Kappa 係数	0.44					

表6. 判定効率表 (CART 法、特微量多数)

分類クラス	参照クラス				計	User's Accuracy
	アカマツ	竹林	スギ	広葉樹		
アカマツ	53	5	58	40	156	0.34
竹林	4	7	1	6	18	0.26
スギ	1	0	28	1	30	0.93
広葉樹	59	10	18	418	505	0.83
計	117	22	105	465	709	
Producer's Accuracy	0.45	0.32	0.27	0.90		
全体精度	0.71					
Kappa 係数	0.42					

表7. 判定効率表 (CART 法、特微量少数)

分類クラス	参照クラス				計	User's Accuracy
	アカマツ	竹林	スギ	広葉樹		
アカマツ	53	5	58	40	156	0.34
竹林	17	6	5	20	48	0.13
スギ	1	0	28	1	30	0.93
広葉樹	46	11	14	404	475	0.85
計	117	22	105	465	709	
Producer's Accuracy	0.45	0.27	0.27	0.87		
全体精度	0.69					
Kappa 係数	0.40					

必要となることである。リモートセンシングデータを使用した樹種分類は、各樹木の持つ特異的な特微量を利用して実行され、とりわけ分光反射特性の差異が利用されることが多い (加藤, 2010)。分光反射特性に加え、NDVI のような植生指数、標高や傾斜のような地形情報、オブジェクトベース画像分類ではテクスチャやオブジェクトのサイズ、形状等の従来のピクセルベース画像分類にはない新しい指数のように、分類に使用できる特微量は増加しており、また分類手法も多岐にわたる (例えば, Johansen and Phinn, 2006; Dobrowski et al., 2008)。そのため、解析者は試行錯誤を繰り返し、対象地の植生図作成に対して、より良い分類精度を有し、費用対効果の高い手順を構築しなければならないであろう。

引用文献

- Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS J. Photogramm. Remote Sens.*, **65**: 2-16.
- Dobrowski, S.Z., H. D. Safford, Y. B. Cheng and S. L. Ustin. 2008. Mapping mountain vegetation using species distribution modeling, image-based texture analysis, and object-based classification. *Appl. Veg. Sci.*, **11**: 499-508.
- 日置佳之. 2007. 日本全国を網羅する現存植生図の応用面から見た課題. *景観生態学*, **11**: 107-112.
- 伊藤史彦・喜多晃平・長澤良太・日野彰彦・浅井樹・中島尚子. 2007. 相観植生図作成における ALOS AVNIR-2画像の利用可能性. *景観生態学*, **11**: 125-132.
- Johansen, K. and S. Phinn. 2006. Mapping structural parameters and species composition of riparian vegetation using IKONOS and Landsat ETM+ data in Australian tropical savannahs. *Photogramm. Eng. Remote Sens.*, **72**: 71-80.
- 鎌形哲稔・原慶太郎・森大・赤松幸生・李雲慶・星野義延. 2006. 高分解能衛星データのオブジェクト指向分類による植生図作成手法の提案. *写測とリモセン*, **45** (1) : 43-49.
- 加藤正人. 2010. 森林の分光反射特性. pp.129-144. 加藤正人編著. *森林リモートセンシング第3版*. 日本林業調査会, 東京.
- 河邑眞・辻野和彦・辻子裕二. 2005. 森林の樹種に関する高分解能衛星画像特性の分析. *写測とリモセン*, **44** (5) : 82-90.
- 小出馨. 2008. 植生フェノロジーの変化に着目した多時期衛星データによる林相区分の精度向上と森林の下層植生状態の推定. *写測とリモセン*, **47** (6) : 4-12.

- 小阪尚子・秋山侃・蔡斌・児島利治. 2007. 高分解能衛星画像のテクスチャ特徴量とスペクトル特徴量を用いたオブジェクト指向型林分タイプ分類. *写測とリモセン*, **46** (2) : 27-36.
- 松英恵吾. 2010. 植生指数. p.172. 加藤正人編著. *森林リモートセンシング第3版*. 日本林業調査会, 東京.
- 村上拓彦. 2010. オブジェクトベース分類. pp.184-185. 加藤正人編著. *森林リモートセンシング第3版*. 日本林業調査会, 東京.
- 長澤良太. 2006. デジタル植生図の技術的課題. *景観生態学*, **11**: 15-25.
- 坂本健二・中山大地・松山洋. 2009. 太陽高度の低い時期における衛星画像の地形効果補正法の提案. *日本リモセン誌*, **29**: 471-484.
- 櫻井聖悟・伊藤達夫・田中和博. 2009. 高分解能衛星データを用いたオブジェクトベース林相区分における地形情報の利用. *日林誌*, **91**: 1-8.
- 竹内渉・安岡善文. 2004. 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. *写測とリモセン*, **43** (6) : 7-19.
- 渡辺知弘. 2006. ALOS の衛星利用技術と植生図化への適用可能性. *景観生態学*, **11**: 35-38.
- Xie, Y., Z. Sha and M. Yu. 2008. Remote sensing imagery in vegetation mapping : a review. *J. Plant Ecol.*, **1**: 9-23.
- Zhang, Q., G. Pavlic, W. Chen, R. Fraser, S. Leblanc and J. Cihlar. 2005. A semi-automatic segmentation procedure for feature extraction in remotely sensed imagery. *Comput. Geosci.*, **31**: 289-296.

Examination of classification methods and feature selection on forest type mapping by object-based image analysis

Kyohei NAKAGAWA¹ and Takuhiko MURAKAMI¹

(Received July 6, 2012)

Summary

Remotely sensed data would be expected to be beneficial for vegetation mapping. In this paper, we reported forest type mapping using SPOT5 data in Sado Island. Object-based image analysis was applied and two classification methods were compared: NN (Nearest Neighbor) and CART (Classification and Regression Trees). The number of features was also examined to evaluate its effect on classification accuracy. The best accuracy is achieved by NN classifier with fewer features. When the classification results obtained through two datasets with NN method were compared, classification with more features showed lower accuracy. NN method with more features does not necessarily contribute to better classification accuracy. However, in the CART method, even if the number of features was varied, selected features were so similar that both accuracies were almost the same. It was suggested that it may be better to examine features carefully regarding its efficiency to separate each class and to sort out valid features in advance.

Bull.Facul.Agric.Niigata Univ., 65(1):57-65, 2012

Key words : Object-based image analysis, SPOT5, forest type classification, Nearest Neighbor (NN) , Classification and Regression Trees (CART)

¹ Graduate School of Science and Technology, Niigata University

* Corresponding author: muratac@agr.niigata-u.ac.jp