

静岡県東部における機械学習を用いたヒノキ林の推定

—空中写真を用いた予備的調査—

小篠凌大^{*1}, 諏訪尚也^{*1}, 安田泰輔^{*2}, 鈴木静男^{*1}

Estimation of *Cypress* tree occupancy in forests by machine learning in the eastern area of Shizuoka Prefecture: A preliminary investigation by aerial photographs

Ryota KOSHINO^{*1}, Naoya SUWA^{*1}, Taisuke YASUDA^{*2}, Shizuo SUZUKI^{*1}

Abstract

Aerial photographs offer broad spatial coverage of generalized forest structure and promise to improve the measurement and mapping of forest properties. The goal of this paper was to investigate the effectiveness of object scale (12×12 pixels) prediction of a species occupancy on object-based image analysis using aerial photographs. The study was carried out on a mountain areas located in Numazu, Kawazu and Izu districts, in the eastern part of Shizuoka Prefecture. The object-based image analysis was conducted using RGR and HSV color spaces to classify the *Cypress* forests which cover the largest part of Shizuoka Prefecture. The random forests ensemble learning approach was used to predict the object scale probability of occurrence for the conifer species. The area under a curve (AUC) of a receiver operating characteristic (ROC) was used to judge classification accuracy. The AUC was improved by increasing the number of training samples in the machine learning and it saturated when training samples exceeded 15,000. The fluctuations of false positive rate, false negative rate and misclassification rate were reduced as the number of decision trees increased, and they became stable for more than 1,000 decision trees. Under the condition of 24,000 training samples and 2,000 decision trees, the classification exhibited high accuracy of over 0.83 with the AUC. The classifications using RGB and HSV color spaces achieved similar accuracies and provided a more visually adequate depiction of the *Cypress* forests. It was concluded that the random forests ensemble learning approach is a powerful machine learning classifier when combined with object-based image analysis using aerial photographs.

Key Words: Aerial photographs, Object-based image analysis, Random forests, Remote sensing

1. はじめに

環境省は自然環境保全基礎調査を行い、全国の植生図の整備や更新を行っている。第6回自然環境保全調査では、植生図の縮尺が1/50,000縮尺から1/25,000縮尺となった。縮尺の変更から作業量が増加し、2013年時点で

全国の約40%の植生図の更新が未完であり^[1]、1999年以降、現存する植生図全体の更新は20年間行われていない^[2]。

近年、地球温暖化に伴い環境の変化が急速になっている。植生情報の管理や生態系の現状把握のため短い周期での定期的な植生図の更新が必要である。しかし、上述した作業量の増加や現場作業者の高齢化により森林の情報管理が困難になってきている。従来の作成方法は、空中写真を目視で読み取り、地図に境界と凡例を入力した予測図を作成する。次に現地調査を行い、予測図を修正

^{*1} 電子制御工学科

Department of Electronic Control System Engineering

^{*2} 山梨県富士山科学研究所

Mount Fuji Research Institute, Yamanashi Prefectural Government.

する。これらの作業を機械学習によって行うことは、植生図の作成頻度を上げることにつながると考えられている^[3]。そこで、空中写真や衛星画像を用いた一括した森林植生図の作成や植生状況の把握が望まれる。

分解能が高いデータの画像分類を行う際、分解能の高さから画素（ピクセル）ベースの画像分類法を用いた場合、同じ植物であっても影などによる微小領域が大量に発生してしまう^[4]。そのためピクセル同士の空間的関係を重視し、形状や周囲との関係などを考慮したオブジェクトベースの分類法が有用であるとされている。オブジェクトベースの分類法では、ピクセルの集合体であるオブジェクトを画像分類の単位としている^[4]。オブジェクトを用いることで、テクスチャの特徴を表現し画像分類に応用することが容易になる。また、植生図の境界線としてオブジェクトの境界線が適用できると考えられ、植生図化に有用であると期待されている^[5]。

静岡県は県土の 64% が森林であり、ヒノキ林の面積は国有林、民有林ともに最も広い^[6]。静岡県全域においてヒノキ林の分類を行うための予備的な調査として、空中写真を用いた画像分類を機械学習によって試みた。

2. 方法

Fig.1 に研究の流れを示す。

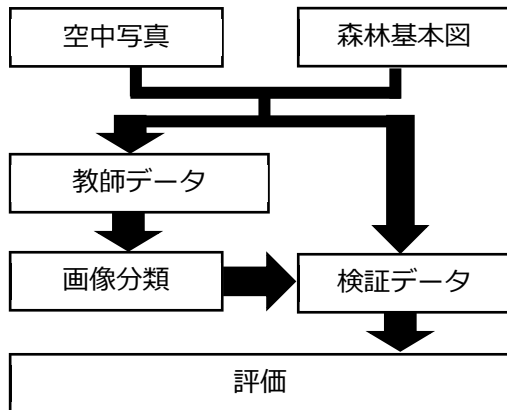


Fig.1 研究の流れ

2.1 デジタルデータ

2.1.1 空中写真データ

本研究で使用する空中写真は、国土地理院が公開している電子国土基本図（カラーオルソ画像）^[7]（2010年4月及び2011年5月）の1/10,000縮尺のものをJPG形式で入手した。空中写真の地上分解能は約0.5mである。空中写真を地理情報システムソフトウェア QGIS (2.18 with Grass) に読み込むために、GitHubGist より入手し

たレイヤ情報データ GISMaps.tsv とプラグイン TileLayerPlugin を用いた。

2.1.2 国有林及び民有林データ




Fig.2 林班境界

国有林野施業実施計画図^[8]を基に作成したものであり、濃くぬりつぶした部分はヒノキを示す




Fig.3 静岡県東部及び伊豆半島における対象領域

国有林のデータは、国有林野施業実施計画図^[8]を入手し、スキャナーにより画像データに変換した。次にスキャンした画像をもとに林班境界を QGIS を用いて手入力で作成し、shape ファイル形式にした (Fig.2)。ここで林班とは森林を字界や尾根、谷等の地形で分けた区画であり、樹種の情報が含まれる。民有林のデータは、shape ファイル形式で入手した^[9]。このファイルには、森林計画図と森林簿が含まれる。

2.2 教師及び検証データ範囲

対象領域は Fig.3 に示す静岡県沼津市(I, II)、伊豆市(III)及び河津町(IV)とした。沼津領域にはヒノキと広葉樹が多く生育し、伊豆及び河津領域ではヒノキとスギが多く生育する。また、Fig.4 は伊豆領域を 4 つに分割し

たものである。それぞれの対象領域で①,④を教師データ範囲、②,③を検証データ範囲とした。



Fig.4 教師及び検証データ範囲の分割例

2.3 画像の処理

Python (3.6)のOpenCV (2.4)ライブラリを用いて空中写真のRGB (赤: Red, 緑: Green, 青: Blue) 色空間からHSV (Hue: 色相, Saturation: 彩度, Value: 明度) 色空間へ変換した。画像分類は、RGB 色空間だけでなく、HSV 色空間も使い、両者の分類精度を比較した。

2.4 テクスチャ解析




Fig.5 テクスチャ解析用の正方形オブジェクト
太い線で区切られた1区画が1オブジェクトに相当し
12×12ピクセルから成る

河邑ら^[10]は対象となる画像にピクセルの集合体である正方形のオブジェクトを作成し、そのオブジェクト内のRGB値の平均と標準偏差を用いてテクスチャ解析を行い良好な結果を得た。そこで本研究でも正方形のオブジェクトを設定し、テクスチャ解析を行った。河邑ら^[10]と同様に、樹木が1、2本入るようにオブジェクトの大きさを12×12ピクセル、計144ピクセルとした(Fig. 5)。

2.5 機械学習

機械学習はランダムフォレスト^[11]を用いた。実行環境は、R (3.5)と機械学習用パッケージrandomForest (4.6)

である。機械学習に用いる統計量として、オブジェクト中に含む各画素のRGB値またはHSV値の平均及び標準偏差を用いた。RGB色空間での画像分類では各オブジェクトにおける画素の赤、緑及び青の各平均及び標準偏差の6個の統計量を使用した。また、HSV色空間では色相、彩度及び明度の各平均及び標準偏差の6個を使用した。

各決定木の分岐点における分岐関数候補の数は、使用する統計量の平方根数が最適であるという研究報告がある^[12]。このため、6個の統計量から2個を分岐関数候補として使用した。1つのオブジェクトに対して、各決定木が二値(0または1)の判断を行い、決定木数の多数決による割合が求まる。0から1までの連続的な値を出力し、この値を竹林分布予測値と定義した。

2.6 精度評価

画像分類の精度を評価するためにReceiver operating characteristic (ROC) 曲線と呼ばれる手法を用いた。横軸に偽陽性率、縦軸に真陽性率をとり、陽性か陰性かを分ける閾値を変化させて曲線が描かれ、主に画像分類の精度評価に用いられる。

ヒノキのオブジェクトを「ヒノキである」、「ヒノキでない」と分類したオブジェクト数をそれぞれ true positive (TP)、false negative (FN)、ヒノキでないオブジェクトを「ヒノキでない」、「ヒノキである」と分類したオブジェクト数をそれぞれ true negative (TN)、false positive (FP)と定義すると、偽陽性率と真陽性率は以下のように表せる。

$$\text{偽陽性率} = \frac{FP}{FP+TN}, \quad \text{真陽性率} = \frac{TP}{TP+FN}$$

ROC 曲線は曲線下の面積である Area under a curve (AUC)で定量的に評価でき、AUCは、0から1の値を連続的にとる。完全な分類は1、全く分類が出来ていないランダムな分類は0.5となる。加えて、偽陰性率と誤答率を以下のように表す。

$$\text{偽陰性率} = \frac{FN}{TP+FN}, \quad \text{誤答率} = \frac{FP+FN}{TP+FP+TN+FN}$$

3. 結果及び考察

3.1 パラメータの決定

画像分類に用いたランダムフォレストの精度に影響する要因として教師データ数と決定木数が挙げられる。これらについて検討した。

本研究は、RGB及びHSV画像に対して教師データ数による分類精度の比較を行った。教師データが増えると

分類精度を表す AUC の値は上昇した (Fig. 6)。しかし、教師データ数が 15,000 から 24,000 に増加しても AUC は、ほぼ同じであった。

Feng ら^[13]及び Ma ら^[14]は、小型無人機 (ドローン) 搭載デジタルカメラにより上空から撮影した都市景観の画像に対して機械学習による植生分類を試みた。オブジェクトベースのこの分類には、アルゴリズムとしてランダムフォレストが用いられ、教師データ数が増加すると草原、林、露出土壤等^[13]、農場、森林、建造物、道路等^[14]の識別精度が上昇したと報告している。本研究でも教師データの数が重要であることが示された。

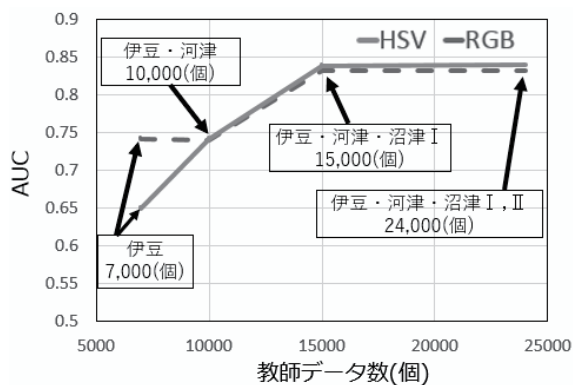


Fig.6 教師データ数による分類精度 (AUC) の比較




Fig.7 決定木の数とエラー確率の関係

教師データ数が十分大きい 24,000 個を使用し、決定木数と分類精度の関係を調べた (Fig. 7)。エラー確率として偽陽性率、偽陰性率、誤答率を用いて評価した。RGB 画像を用いた際に、決定木の数が 1,000 本以上になるとエラー確率は大きく変動しなくなった。

前述の Feng ら^[13]は、ランダムフォレストの決定木数を変化させ都市景観の分類精度を比較した。決定木数が増加すると分類精度も高まるが、ある数以上になると分類精度は安定する。この安定する決定木の数は、オブジ

ェクトのサイズ (1 オブジェクトに含まれるピクセル数) が小さくなるにつれ大きくなったと報告している。本研究では、安定する決定木数を求めることができた。しかし、オブジェクトのサイズは一定であるため、今後そのサイズを検討する必要がある。

3.2 分類精度の評価

前述の結果から決定木 2,000 本、教師データ 24,000 個を用いてランダムフォレストで分類を行った際の ROC 曲線を作成した (Fig. 8)。RGB と HSV の間で大きな違いは見られなかった。

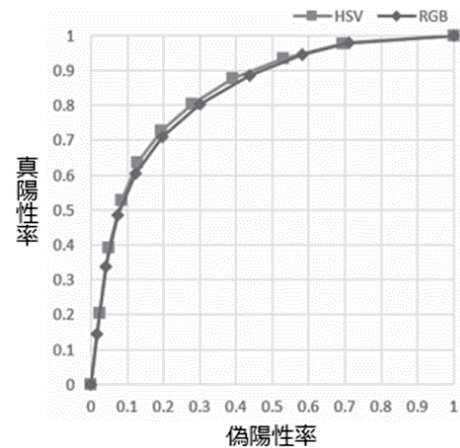


Fig.8 Receiver operating characteristic (ROC) 曲線

Table 1 色空間別の分類精度に関する比較

色空間	閾値	真陽性率	偽陽性率	AUC
RGB	0.5	0.71	0.20	0.83
HSV	0.5	0.73	0.19	0.84

座標 (0, 1) と ROC 曲線との距離が最小となる点は、画像分類する (陽性か陰性かを分ける) 際の閾値として重要な値である。今回の分類において、HSV 及び RGB の最適な閾値は、0.5 であった。この値に基づいて Table 1 では、色空間別の分類精度に関して比較した。RGB 及び HSV では真陽性率、つまりヒノキであるとわかっているオブジェクトをヒノキであると予測した割合が、0.71 及び 0.73 であった。偽陽性率、つまりヒノキでないわかっているオブジェクトをヒノキであると予測した割合が、0.20 及び 0.19 であった。AUC の値は 0.83 及び 0.84 であった。RGB 画像と HSV 画像による分類精度に大きな違いは見られなかった。

機械学習後、閾値を 0.5 として検証用画像に対してヒノキであるオブジェクトを予測した結果を Fig.9 に示した。この図から比較的良好にヒノキ林を予測しているこ

とがわかる。しかしながら、ヒノキ林でない箇所に対するヒノキ予測及びヒノキ林である箇所に対する非ヒノキ予測がある程度見られる。これは、Table 1 の偽陽性率からも裏付けられる。このような予測間違いを低くすることが今後の課題である。今回の結果からは、RGB と HSV による大きな違いは見られなかった。今後は、同場所の撮影時期による違いを検討することで、より汎用的なモデルに仕上げる必要がある。




Fig.9 画像分類による結果

(a) RGB 画像と (b) HSV 画像に対して、閾値 0.5 におけるヒノキ林 (灰色) 及び非ヒノキ林 (白) の予測結果を示す (黒線はヒノキ林縁)

4. 要約

本研究は、静岡県で最も広大な面積のヒノキ林に対する機械学習による分類方法を空中写真を用いて検討した。沼津市、伊豆市、河津町の領域において、ヒノキ分類の教師データを作成した。これには RGB 及び HSV 色空間を用い、それぞれの平均並びに標準偏差を特徴量とした。ランダムフォレストによる画像分類の精度は、決定木数及び教師データ数が増加するとともに分類精度は向上し、決定木 1,000 本以上、教師データ 15,000 個以上を越えるとほぼ変化しないことが確認された。決定木 2,000 本、教師データ 24,000 個で分類を行った結果、RGB 色空間による分類では AUC の値は 0.83、HSV 色空間による分類では 0.84 と良好な結果を得ることができた。RGB 色空間と HSV 色空間による分類精度に大きな違いは見られなかった。今後、広域に調査し静岡県全域における機械学習によるヒノキ林の推定を目指す予定である。

5. 謝辞

本研究を進めるにあたり、静岡森林管理署より国有林野施業実施計画図、静岡県森林計画課より森林計画図と森林簿のデータをご提供頂きました。ここに記して謝意を表します。

6. 参考文献

[1] 環境省自然環境局生物多様性センター: 平成 24

年度自然環境保全基礎調査 (第 7 回) 総合とりまとめ業務報告書, 126pp, 環境省自然環境局生物多様性センター, (2013).

- [2] 環境省自然環境局生物多様性センター: 植生調査の概要, <<http://gis.biodic.go.jp/webgis/sc-007.html>>, (アクセス日: 2017/10/17).
- [3] 長谷川奈美, 星野義延, 原慶太郎, 鎌形哲稔, 中尾勝洋: 高分解能衛星データを用いた森林タイプ判別: 佐倉市の里山地域を例として, 植生学会誌, 30, (2013), 25-35.
- [4] 村上拓彦: 第 8 章, 画像処理(III)分類, 加藤正人編, 森林リモートセンシング, J-FIC, (2004), pp. 107-117.
- [5] 鎌形哲稔, 原慶太郎: オブジェクトベース画像解析による植生図化における植生界抽出と分類精度の評価, 植生学会誌, 27, (2010), 83-94.
- [6] 静岡県経済産業部森林・林業局森林計画課: 静岡県森林・林業統計要覧平成 29 年度版, 170pp, 静岡県経済産業部森林・林業局森林計画課, (2018).
- [7] 国土地理院: 地図・空中写真閲覧サービス, <<http://maps.gsi.go.jp>>, (アクセス日: 2018/02/22).
- [8] 静岡森林管理署: 富士森林計画区第 4 次国有林野施業実施計画図, 静岡森林管理署, (2010).
- [9] 静岡県森林計画課: 森林簿・森林計画図, 静岡県森林計画課, (2015).
- [10] 河邑眞, 辻野和彦, 辻子裕二: 森林の樹種に関する高分解能衛星画像特性の分析, 写真測量とリモートセンシング, 44, (2005), 82-90.
- [11] Breiman L: Random forests, Machine Learning, 45, (2001), 5-32.
- [12] 波部斉: ランダムフォレスト, 研究報告コンピュータビジョンとイメージメディア (CVIM), 2012, (2012), 1-8.
- [13] Feng Q, Liu J, Gong J: UAV remote sensing for urban vegetation mapping using random forest and texture analysis, Remote Sensing, 7, (2015), 1074-1094.
- [14] Ma L, Fu T, Blaschke T, Li M, Tiede D, Zhou Z, Ma X, Chen D: Evaluation of feature selection methods for object-based land cover mapping of unmanned aerial vehicle imagery using random forest and support vector machine classifiers, ISPRS International Journal of Geo-Information, 6, (2017), 51: doi: 103390/ijgi6020051.