研究ノート

UAV 画像の撮影時期による針葉樹分類モデルの精度比較

藤 平 光 希^{1,*}・トウソウキュウ²・加 藤 正 人²Accuracy Comparison of Conifer Classification Models Using UAV Images
Acquired in Different MonthsMitsuki Fujihira^{1,*}, Songqiu Deng² and Masato Katoh²

I. はじめに

UAV (Unmanned Aerial Vehicle) は低コストで高い空間分解能を得ることができるという利点から (Anderson and Gaston, 2013) 広域での森林資源把握に有効であり, 近年活用が増加している (村上, 2018)。単木レベルの樹種分類においても UAV の活用事例は多く, 多様なアルゴリズムを用いた研究が行われている (Fassnacht ら, 2016)。例えば, Deng ら (2016) は UAV で取得した RGB 画像と航空レーザ計測データを用いて多様な機械学習アルゴリズムについて樹種分類の精度を比較し, 評価を行った。近年では, ディープラーニングの 1 種である畳み込みニューラルネットワーク (Convolution Neural Network; CNN) やそこから派生したアルゴリズムを利用した分類が盛んに行われている。Onishi and Ise (2018) は UAV で得られたオルソモザイク画像や樹高傾斜モデルを使用して GoogLeNet (Szegedy ら, 2015) による樹種分類を実施し, Nezami ら (2020) は UAV を用いて取得した RGB 画像とハイパースペクトル画像をもとに 3D-CNN (Ji ら, 2013) を使って樹種分類を行った。

上記の先行研究では 1 時期に撮影されたデータのみを使用しているが, 植物体にはフェノロジーと呼ばれる季節性の形態変化があり, これは樹種分類の精度に影響を与える特性であることが知られている (Fassnacht ら, 2016)。航空写真と衛星画像を用いた 2 つの研究では, 春季と秋季の 2 時期の画像を組み合わせることで分類精度の向上が期待できることが示されている

(Hill ら, 2010; Mickelson ら, 1998)。また, Voss and Sugumaran (2008) は, ハイパースペクトル画像を使用した樹種分類結果の比較により, 夏季よりも秋季のほうが安定した結果が得られることを示した。しかし, これらの研究では 2 時期あるいは 3 時期での比較にとどまっており, 分類に最適な時期を特定するためにより短いインターバルでの精度比較が望まれる。

そこで本研究では, 低コストかつ手軽に取得することができる UAV による RGB 画像に着目し, 5 月から 11 月まで毎月 1 回の頻度でデータを取得することで画像の撮影時期が分類精度に与える影響をより詳細に明らかにすることを目的とした。また, 2 種類のアルゴリズムを用いて樹種分類を行い結果を比較することで, アルゴリズムによる精度推移の違いについても検討した。

II. 対 象

本研究は信州大学農学部 (長野県上伊那郡南箕輪村) の構内演習林に生育している針葉樹 3 種 (アカマツ, カラマツ, ヒノキ) を対象に行なった。調査地の UAV 画像を図-1 に, 調査地内に存在する対象木の樹種別本数を表-1 に示す。調査地内には対象樹種以外にもサワラ, スギ, 広葉樹等が少数生育しているが, サンプル数が少ないため対象から除外した。また, 対象期間は 2019 年 5 月から同年 11 月までの 7 か月である。

* 連絡先 (Corresponding author) E-mail: 20as411a@shinshu-u.ac.jp

1 信州大学大学院総合理工学研究科農学専攻 (399-4598 長野県上伊那郡南箕輪村 8304)

Department of Agriculture, Graduate School of Science and Technology, Shinshu University, 8304 Minamiminowa-Vill., Kamiina-Dtrct., Nagano 399-4598, Japan

2 信州大学先鋭領域融合研究群山岳科学研究拠点 (399-4598 長野県上伊那郡南箕輪村 8304)

Institute for Mountain Science, Interdisciplinary Cluster for Cutting Edge Research, Shinshu University, 8304 Minamiminowa-Vill., Kamiina-Dtrct., Nagano 399-4598, Japan

図-1 調査地の UAV 画像
(2019年5月31日撮影)

表-1 対象木の樹種別本数

樹種	本数 (本)
アカマツ	1035
カラマツ	439
ヒノキ	667

Ⅲ. 方 法

1. 参照データの作成

2019年5月31日、6月21日、7月1日、8月22日、9月20日、10月21日、11月25日の7回にわたって DJI Phantom 4 Pro および機体付属のカメラを用いて調査地の空撮を行い、得られた写真から SfM 解析を用いて各月1枚ずつのオルソモザイク画像（分解能 25cm）を作成した。次に、QGIS 上でこれらのオルソモザイク画像を目視判読し、単木ごとに樹冠ポリゴンの作成および樹種情報のラベリングを行うことで参照データを作成した。

2. 樹種分類モデルの作成

本研究では、各月のデータセットに対して2種類のアルゴリズムを用いて樹種分類モデルの作成および評価を行った。

(1) SVM (Support Vector Machine)

1つ目のアルゴリズムは、針葉樹の分類に有効であるとされるノンパラメトリック機械学習手法の1つである SVM (Vapnic and Lerner, 1963) である (Deng ら, 2016)。SVM は与えられた特徴量の分布から、分類クラス間の境界を設定することで分類学習を行う。このとき、境界の超平面と分類クラス内の各点との距離の最小値 (マージン) が最大となるため、与えられた特徴量に対して正確な分類が期待されるのが SVM の特徴である。QGIS の地域統計プラグインを用いて、オルソ画像の RGB 各バンドのピクセル値について樹冠ポリゴン内の平均値、中央値、標準偏差、範囲 (最大値 - 最小値)、最頻値を算出し、計15項目の特徴量を抽出した。この処理を各月のデータに対して行い、月ごとの学習用データセットとした。学習精度を向上させるために前処理として特徴量の正規化を行い、分類器のカーネルは2次多項式 (Boser ら, 1992) を使用した。その他のパラメータについては表-2 に示すとおりである。

表-2 SVM モデルに使用したパラメータ

*scale は $1 / (\text{特徴量数} \times \text{特徴量の分散})$ で求められる値

パラメータ	設定値
C	1.0
gamma	scale*
coef 0	0.0

(2) CNN (Convolution Neural Network)

もう1つのアルゴリズムは、CNN による画像認識である。このアルゴリズムでは、入力された画像に対して自動的に特徴量を抽出し、学習を行う。QGIS を使用して、各樹冠ポリゴンの重心を中心とした129ピクセル (約2.6m) 四方の正方形に単木画像を切り出す処理を各月のオルソ画像に行うことで学習用データセットとした。本研究では、CNN を構築する環境およびライブラリとして、ともにオープンソースの Python ライブラリである Theano 1.0.5 と Keras 2.4.3 を使用した。今回使用した CNN モデルの層構造を図-2 に、パラメータを表-3 に示す。記載のない

図-2 本研究で用いた CNN モデルの層構造

表-3 CNN モデルに使用したパラメータ

パラメータ	設定値
filter	32
kernel_size	(3, 3)
pool_size	(2, 2)
Dropout	0.25
batch_size	64
epochs	70
optimizer	sgd

パラメータについてはデフォルト値を使用した。

3. モデルの評価

モデルの評価には5分割交差検証を用いた。データセットをランダムに5分割し、訓練データと検証データの組み合わせを変えながら学習および推定を行うことで、すべてのデータに対して推定結果が得られる。この推定結果の正答率（(正解数/全データ数)×100）をモデルの精度として評価を行った。

IV. 結果と考察

撮影時期7か月×アルゴリズム2種類の計14通りのモデルについてそれぞれ評価を行った結果を図-3に示す。

図-3 SVMおよびCNNによる画像撮影月別分類モデル精度

SVM, CNNともに5～7月と11月のデータから作成されたモデルは精度が高く、8月、9月はモデルの精度が低下する傾向にあることがわかった。アルゴリズムごとに詳細な傾向を比較すると、SVMでは5月のモデルと11月のモデルの精度が同程度であるのに対してCNNでは11月のモデル精度が5月と比較して8.27ポイント高いという結果になった。また、6月のモデル精度はSVM, CNNともに5月および7月よりも低いですが、SVMは下がり幅が前後の月と比べて小さいのに対し、CNNでは前後の月と比べて約5ポイン

ト精度が低くなった。

また、混合行列を用いて誤分類の傾向を見ると、カラマツとヒノキは全体的にアカマツに誤分類されやすいことがわかった。8月および9月のデータではSVM, CNNともにアカマツとして誤分類されるカラマツの数が多く、これらの時期に分類精度が低下した直接的な原因であると考えられる。

これらの結果から、針葉樹の樹種分類モデルはどちらのアルゴリズムを用いた場合でも初夏および秋季の5月、7月、11月に撮影した画像を用いると精度が高くなり、夏季である8月および9月に撮影した画像では精度が低くなることがわかった。フェノロジーによる色調の変化が樹種によって異なるためこのような精度の推移が見られると考えられる。カラマツは落葉樹であるため開葉期である初夏と紅葉期である秋季には色調が大きく変化することが報告されており（小野ら, 2015）、これが5月および11月のデータで分類モデルの精度が高くなった原因であると推察される。ヒノキおよびアカマツについても葉量に季節性的変化がある（宇津木ら, 2001；齋藤, 1990）ため、これらも分類モデルの精度に影響していると考えられる。

また、今回使用したデータセットではSVMと比べてCNNの方が画像の撮影時期によるモデル精度の差が大きく、樹木のフェノロジーの変化に敏感であると言える。そのため、CNNによる樹種分類モデルを作成するには画像の撮影時期に注意する必要があると考えられる。

V. おわりに

本研究ではRGB画像の撮影時期が樹種分類モデルの精度に与える影響について検討したが、解明すべき点が複数残っている。今回得られた結果から樹種分類モデルの精度推移は対象樹種のフェノロジーの違いに起因すると考えられるが、フェノロジーに影響を与える因子は季節だけではない。例えばカラマツの開葉や落葉時期には標高や年次による変動がある（只木ら, 1994）ため、調査地のサイト数や撮影年次を追加して樹種分類モデルの精度推移をより詳細に検討する必要がある。

本研究ではSVMモデルのほうがCNNモデルと比べて全体的に精度が高いという結果が得られたが、これはCNNに対して訓練データのサンプル数が少なかったためだと考えられる。CNNに代表されるディープラーニングには一般に膨大な学習用データセットが必要だとされているが、本研究で用いたデータセットでは不十分だった可能性がある。このため、画像の反転や回転によるデータセットの拡張を行うこ

とで精度の向上が期待できる。また、今回は針葉樹3種のみを対象としたが、対象樹種を追加することで汎用性の高い結果を得られると考えられる。今後はこれらの課題の解明にも取り組んでゆきたい。

引用文献

- Anderson, K. and Gaston, K.J. (2013) Lightweight unmanned aerial vehicles will revolutionize spatial ecology, *Front. Eco. Environ.* 11(3), 138–146.
- Boser, B.E., Guyon, I. M. and Vapnik, V.N. (1992) A training algorithm for optimal margin classifiers, COLT'92: Proceedings of the fifth annual workshop on Computational learning theory, 144–152.
- Deng, S., Katoh, M., Yu, X., Hyyppä, J., and Gao, T. (2016) Comparison of Tree Species Classifications at the Individual Tree Level by Combining ALS Data and RGB Images Using Different Algorithms, *Remote Sens.* 2016, 8(12), 1034.
- Fassnacht, F.E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L.T., Straub, C. and Ghosh, A. (2016) Review of studies on tree species classification from remotely sensed data, *Remote Sens. Environ.* 186, 64–87.
- Hill, R.A., Wilson, A.K., George, M. and Hinsley, S.A. (2010) Mapping tree species in temperate deciduous woodland using time-series multi-spectral data, *Appl. Veg. Sci.* 13(1), 86–99.
- Ji, S., Xu, W., Yang, M. and Yu, K. (2013) 3D convolutional neural networks for human action recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(1), 221–231.
- Mickelson, J.G., Civco, D.L. and Silander, J.A. (1998) Delineating forest canopy species in the northeastern United States using multi-temporal TM imagery, *Photogramm Eng. Remote. Sens.* 64(9), 891–904.
- 村上拓彦 (2018) UAV を利用した森林リモートセンシング, *日本リモートセンシング学会誌*, 38(3), 258–265.
- Nezami, S., Khoramshahi, E., Nevalainen, O., Pölönen, I. and Honkavaara, E. (2020) Tree Species Classification of Drone Hyperspectral and RGB Imagery with Deep Learning Convolutional Neural Networks, *Remote Sens.* 2020, 12(7), 1070.
- Onishi, M. and Ise, T. (2018) Automatic classification of trees using a UAV onboard camera and deep learning, *arXiv*, arXiv: 1804.10390.
- 小野朗子, 林田佐智子, 小野厚夫 (2015) デジタルカメラを用いた落葉針葉樹カラマツ林の植生解析, *写真測量とリモートセンシング*54(1), 20–31.
- 齋藤秀樹 (1990) アカマツ林の落葉の季節変動と林分間にみられる同調性, *京都府立大学学術報告 農学*(42), 47–57.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A. (2014) Going Deeper with Convolutions, *arXiv*, arXiv: 1409.4842.
- 只木良也, 北村秀夫, 蟹江清丞, 佐野弘美, 重松明子, 大津慎一 (1994) 標高に伴うカラマツの葉の開葉と落葉の挙動, *日生態会誌*44, 305–314.
- 宇津木玄, 荒木眞岳, 川崎達郎, 石塚森吉 (2001) ヒノキ人工林における葉面積指数の季節変化の推定, *日林誌*83(4), 359–362.
- Vapnik, V. and Lerner, A. (1963) Pattern recognition using generalized portrait method, *Automation and Remote Control*, 24, 774–780.
- Voss, M. and Sugumaran, R. (2008) Seasonal effect on tree species classification in an urban environment using hyperspectral data, LiDAR, and an object-oriented approach, *Sensors* 8(5), 3020–3036.
- (2020年11月26日受付)
(2021年2月2日受理)