

森林空撮画像の深層学習による樹冠領域推定手法の開発

近藤 正一, 全 慶樹, 藤澤 怜央, 堀 武司

Development of Technique for Tree Canopy Area Estimation using Deep Learning for Forest Aerial Images

Shouichi KONDOU, Keiki ZEN, Reo FUJISAWA, Takeshi HORI

抄 録

現在、道内人工林では樹木の多くが利用に適した樹齢に達してきて、伐採や育林に係る作業を効率的に進めることが重要である。森林管理者は伐採や管理を行う際、管理する森林内にどれだけ木があるのか把握するために資源量調査を実施している。資源量調査では、樹高や胸高直径（人の胸の高さにおける立木の直径）、材積（幹の部分の体積）等を計測する。計測の際は、各立木付近まで近づき人手で直接計測してきて、木以外の植物も生い茂り傾斜もある森林内においては非常に重労働である。近年は、UAVで空撮した画像から資源量を推定する方法が注目されているが、熟練者による高度なデータ解析作業が必要なことから自動化が困難とされてきた。

本研究では、これらのデータ解析作業を自動化し、森林資源量推定の省力化を実現するために、空撮画像から各立木の位置及び樹冠領域を推定する手法を開発した。

キーワード：森林資源量調査, UAV, 深層学習, 物体認識, 画像解析

Abstract

At present, many of the trees in the plantation forests in Hokkaido have reached an age suitable for use, and it is important to efficiently carry out work related to logging and forest growth. When conducting logging and management, forest managers conduct resource surveys to understand how many trees are available in the forests they manage. In resource surveys, measurements are taken of tree height, diameter at breast height (the diameter of a standing tree at the height of a person's chest), and timber volume (the volume of the trunk). This is very hard work in a forest where plants other than trees grow thickly and there are slopes. In recent years, the method of estimating the amount of resources from aerial images taken by UAVs has been attracting attention, but it has been considered difficult to automate because it requires advanced data analysis work by skilled personnel.

In this study, we developed a method for estimating the location and canopy area of each standing tree from aerial images in order to automate these data analysis tasks and realize labor-saving estimation of forest resources.

KEY-WORDS : Forest Resources Survey, UAV, Deep Learning, Object Recognition, Image Analysis

1. はじめに

北海道の人工林は約148万haあり、その多くが利用に適した時期を迎えて今後伐採量の増加が見込まれる一方、人口減少や高齢化から林業従事者が減少している。このため、林業における作業の効率化が求められている。森林管理者は、木材生産量の見積もりや伐採、育林の作業計画を立てる際、森林内にある立木の本数、種類、太さや高さ等を把握するため

に資源量調査を行うが、資源量調査で最も一般的なのは、調査者が森林内に入り込み、輪尺や測高機により一本ごとに直接計測する方法（図1）である。大変な労力がかかるため作業の省力化が求められている。また、広範囲の資源量調査を行う手法として、有人航空機に搭載したLiDAR（Light Detection And Ranging, レーザー光を用いた測距センサ）により計測する手法がある。公共事業による基盤データの整備として利用されることがあるが、非常に大がかりで高コス

事業名：経常研究

課題名：UAVを活用した低コスト森林調査手法の研究



図1 輪尺により胸高直径を計測する様子

トであるため個別の森林管理者が実施するのは困難である。一方、近年は、UAVに搭載したカメラによる空撮が安価かつ手軽に行えるようになったことから、森林の空撮画像から資源量を調査する方法が注目されており、林野庁から調査方法のマニュアル¹⁾(UAV立木調査マニュアル)も発行されている。この方法は、適切な条件で空撮を行うことで、特別な計測機器を使用せずに各立木の樹種及び材積(幹の部分の体積)を推定することができ非常に有用である(図2)。しかし、解析作業のうち立木位置及び樹冠領域の取得(図2(c))は、熟練者による高度なデータ解析作業が必要なことが課題である。

本研究では、この課題を解決し森林資源量調査の省力化を行うために、空撮画像から各立木の位置及び樹冠領域を推定する深層学習を用いた画像解析技術を開発した。また、道内

人工林の主要な樹種であるトドマツに開発した手法を適用し、有効性を検証した。

2. 空撮画像による森林資源量推定

図2に示した森林資源量調査方法の各処理について説明する。

まず、図2(a)の空撮画像の取得では、市販のUAVの自動航行ソフトを用いることで可能である。自動航行ソフトは、飛行経路や撮影のタイミングを事前に設定し、UAVを自動航行させることが可能なソフトウェアである。これにより、図2(b)でオルソ画像及びDSMの取得に適した画像を取得するための飛行経路や撮影条件を簡単に設定することができる。なお、空撮の際は、図3に示す空撮画像の例のように、同じ地点が複数の画像に写るように撮影することが重要である。左右の画像は違う視点から撮影しているが、大部分(破線で囲った枠内)には同じ地点が写っている。

図2(b)のオルソ画像及びDSM(Digital Surface Model, 樹木や建築物等を含めた地球表面の高さを表す3次元データ)の取得では、空撮画像群にSfM/MVS(Structure from Motion/Multiple View Stereo, 多視点画像から対象の高密度な3次元メッシュモデルを生成する技術)を適用することで、森林の3次元形状(図4)及びオルソ画像(図5)を取得する。オルソ画像は、どの地点でも真上から歪まないように空撮画像を変換したもので、被写体の正しい位置と大きさが得られる。SfM/MVSは、市販のソフトウェア等ではほぼ自動で解析できる。図5(a)のオルソ画像への変換前の空撮画像では、画面端の立木が斜めに写り幹が見えているが、



図2 空撮画像による森林資源量調査の流れ




図3 空撮画像の例





図4 空撮画像による3次元形状(DSM)推定例



(a) 変換前の空撮画像 (b) オルソ画像

図5 オルソ画像の例

図5 (b)のオルソ画像では真上から見たように幹が見えなくなっているのが確認できる。

図2 (c)の立木位置及び樹冠領域の取得は、UAV立木調査マニュアルにおいて、市販の地理情報システムを使った方法が示されているが、データに応じた適切なパラメータ設定が必要であり、自動化が困難である。本研究では、このシステムに頼らずに、深層学習を用いて立木位置及び樹冠領域を推定する手法を開発した。手法の詳細は次章で説明する。

最後に、図2 (d)の樹高、胸高直径、材積の推定について、それぞれの推定方法を説明する。樹高推定では、図6に示すように、得られた森林の3次元形状と国土地理院等から得られる地表高データの差分を取ることで、各立木の樹高を計測できる。胸高直径推定については、立木の幹全域は空撮画像には写らないため太さを直接計測することはできないが、胸高直径と樹冠投影面積(図7)から推定することができる¹⁾。オルソ画像は一画素あたりの実寸がわかるため、樹冠領域がわかれば樹冠投影面積を求められ、胸高直径の推定ができる。材積については、樹高と胸高直径から推定可能であることが知られている²⁾。

3. 樹冠領域取得を自動化する手法

3.1 オルソ画像からの樹冠領域推定

オルソ画像から樹冠領域を推定する手法の実現のために、深層学習による画像の領域分割手法であるMask R-CNN³⁾を用いた。Mask R-CNNは、入力画像からニューラルネットワークによって抽出した特徴量を元に、物体の位置検出、カテゴリ分類及び領域分割を同時に行う手法である。図8にMask R-CNNによる樹冠領域推定手法を示す。オルソ画像から特徴抽出層により特徴量を抽出し、物体検出により立木位置を、領域分割により樹冠領域を推定している。また、特徴点検出処理を追加することで、樹頂点位置の推定も同時にできるようにした。



..... DSM (表層高データ、UAVで取得)
 --- DEM (地表高データ、国土地理院等)
 樹高 = DSM - DEM

図6 樹高の求め方

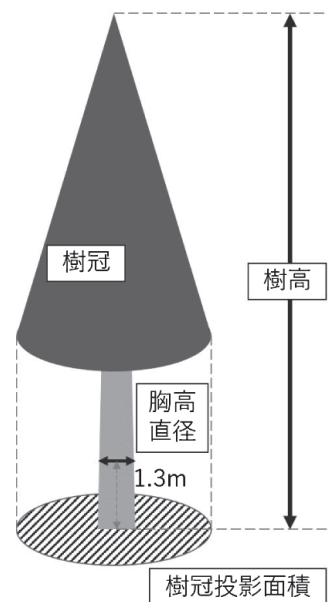


図7 立木各部の名称

Mask R-CNNの学習用データは、図9のようにオルソ画像内の各立木に対して、樹冠領域の輪郭及び樹頂点の位置を手手で記録することで作成した。学習用及び評価用のオルソ画像の解像度は0.05[m/pixel]とし、1,024×1,024画素ごと

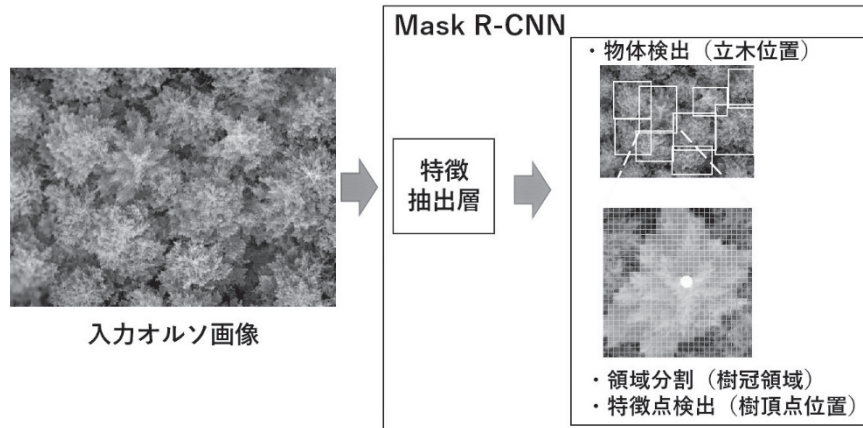


図8 オルソ画像からの樹冠領域推定手法






図9 人手で与えた樹冠領域と樹頂点位置
(多角形：樹冠領域，点：樹頂点)



635本で学習 3,338本で学習
図10 Mask R-CNNによる
樹冠領域及び樹頂点の推定結果

に分割したものを使用した。また、各画像に対して回転や切り抜き、拡大・縮小を適用したものも加え、学習用のデータを拡張した。特徴抽出層はResNet-101⁴⁾を使用した。

トドマツ林のオルソ画像に対して学習を行い、未使用のオ



提案手法 従来手法 (Watershed法)
図11 従来手法との比較

ルソ画像に対して推定した結果の一例を図10に示す。オルソ画像のみから各立木の樹冠領域及び樹頂点を推定できていることが確認できた。また、学習に使用するデータの数が増えると、図10の破線の楕円で囲った部分からわかるように未検出の立木が減り、樹冠領域の形状もより正確に推定できることが確認できた。

図11に、森林の3次元形状データから樹冠領域を推定する

際に従来から用いられている Watershed 法による結果と、本手法による推定の結果を比較したものを示す。従来手法では形状情報のみから樹冠領域を判断するため、破線の楕円で囲った広葉樹が存在する部分を誤って検出しているが、提案手法では適切にトドマツの樹冠のみを検出できることを確認した。

3.2 オルソ画像と高さ情報から樹冠領域推定

前節でオルソ画像から Mask R-CNN により樹冠領域を推定する手法を示したが、さらに精度向上を図るためにオルソ画像及び森林の 3 次元形状の両方を用いて樹冠領域を推定する手法を開発した。

図12に手法の詳細を示す。空撮画像から計算した 3 次元形状に対して図6で示した手法を適用して得られた高さ情報は、格子状に並んだセルに高さの値を持つデータである。この高さの値を 0～255の値に正規化することで画像と同様に扱う

ことができるため、オルソ画像のカラー (RGB) データに正規化した高さデータを加えて 4 チャンネルの画像とみなして特徴抽出層に入力する。樹冠推定には、深層学習による領域分割手法である Hybrid Task Cascade⁵⁾を用いた。Hybrid Task Cascadeは、Mask R-CNNをベースとして、物体検出や領域分割を行うための識別器を複数の閾値で多段に連ねることで推定精度を向上させる手法である。特徴抽出層は、より高解像度の特徴を扱える HRNet⁶⁾に変更した。樹頂点の位置の推定については、高さ情報を使用できるようになったため、Hybrid Task Cascadeで直接推定はせず、樹冠領域内のうち最大の高さを持つ位置を樹頂点位置とすることとした。

学習用データの作成手順は、3.1節の手法と同様であるが、樹頂点位置を高さ情報から推定するように変更したため、樹冠領域のみ人手で記録した。また、データの拡張は、回転や拡大・縮小等の幾何変換に加え、明度やコントラストの変更

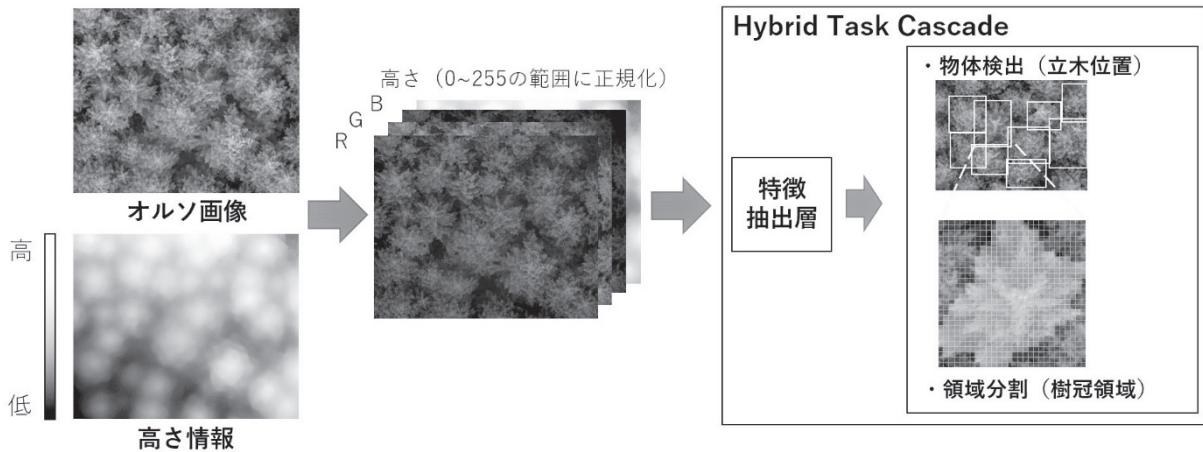


図 12 オルソ画像と高さ情報による樹冠領域推定手法




図 13 樹冠領域推定結果の比較

表1 立木の検出精度

	実際の本数	検出できた本数	検出成功率(%)	RMSE(m ²)	平均誤差率(%)
林分A	145	121	83.4	2.01	17.8
林分B	156	148	94.9	1.85	8.36
林分C	252	227	90.1	4.91	13.89
合計	553	496	89.7	3.29	13.2

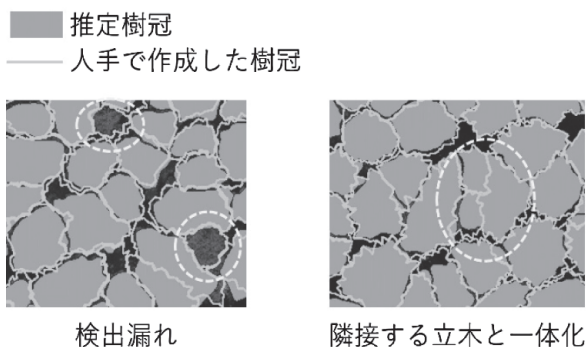


図14 主な検出失敗例

等の色情報を変化させる処理を追加した。

図13に樹冠領域推定結果を示す。破線で囲った部分を見ると、3.1節の手法では検出できていなかった立木が正しく検出できるようになっていることがわかる。

3.3 推定精度の評価

地上において位置、樹高及び胸高直径を計測した立木553本（3林分）について、3.2節で示した手法を適用して検出性能を評価した。

表1に立木検出結果を示す。推定した樹冠と実際の樹冠の重なりが小さいものに関しては検出失敗とした。林分ごとにばらつきはあるが、合計すると89.7%の立木の検出に成功した。図14に示すように、検出に失敗したパターンは、検出漏れと、隣接する立木と一体化してしまった場合が多く、いずれも立木が密集している場所で樹冠の小さい立木が多かった。Hybrid Task Cascade等の領域分割手法は、あらゆる場面の画像、あらゆるカテゴリや大きさの物体を満遍なく検出できるように設計されていることが理由の一つと考えられる。森林の空撮画像のように、似たような見た目の物体が密集している画像に特化したアルゴリズムに改良することで検出成功率を向上させることが可能と考えられる。また、一般に画像解析では、入力データの質が解析結果に影響するため、高品質なオルソ画像及び高さ情報を取得することでも検出が向上すると考えられる。これは、空撮時の条件（風速、天候、カメラ性能、撮影設定等）によるところが大きいので、本手法を利用する際は、これらの条件を整えて空撮を行うことが重要である。

推定した樹冠面積と人手で算出した樹冠面積を比較した結果については、林分ごとのばらつきはあるが、合計で

RMSE（平均二乗偏差）が3.29 m²、平均誤差率は13.2%だった。樹冠面積から胸高直径を推定する統計モデルを適用して胸高直径に換算すると3.5%（胸高直径30cmの立木に対して約1.05cmの誤差）で、概ね良好な結果が得られた。

4. おわりに

森林資源量調査を省力化するために、深層学習による画像解析技術を用いて空撮画像から各立木の樹冠領域を推定する手法を開発した。森林の3次元形状のみから樹冠領域を推定する従来のWatershed法と比べて良好な結果が得られた。また、画像と3次元形状を組み合わせる樹冠領域を推定する手法を開発した。地上で計測した結果と比較したところ、89.7%の立木の樹冠を検出でき、樹冠面積から推定した胸高直径は誤差3.5%だった。

今後は、本手法を活用した森林資源量推定サービスの実用化を目指した研究開発を進める予定である。

参考文献

- 1) 林野庁: UAV立木調査マニュアル, (2019)
- 2) 中島広吉: 北海道立木幹材積表, (1950)
- 3) Kaiming He, Georgia Gkioxari, Piotr Dollar, Ross Girshick: Proceedings of the IEEE International Conference on Computer Vision, pp. 2961-2969, (2017)
- 4) Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun: Deep residual learning for image recognition, Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 770-778, (2016)
- 5) Kai Chen, Jiangmiao Pang, Jiaqi Wang, et al.: Hybrid Task Cascade for Instance Segmentation, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 4974-4983, (2019)
- 6) Ke Sun, Bin Xiao, Dong Liu, Jingdong Wang: High-Resolution Representations for Labeling Pixels and Regions, Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 5693-5703, (2019)