

テーマ番号	1EP14			
プロジェクト テーマ	和文	深層学習に基づく林内全天球画像からの森林資源量計測システムに関する研究		指導教員 長田 茂美 教授
	英文	Research on the Forest Measurement System from Omnidirectional Image in the Forest Based on Deep Learning		
プロジェクト メンバー	4EP1-06 大庭 夕 (ONIWA Yu)		4EP2-22 櫻井 拓実 (SAKURAI Takumi)	
	4EP2-26 清水 健寛 (SHIMIZU Takehiro)		4EP2-52 藤代 翔也 (FUJISHIRO Shoya)	

Abstract Forest resources in Japan have grown mature as more than half of the forests planted after World War II are now over 50 years old. However, stable timber supply has not been achieved in response to the domestic demand, and the wood self-sufficiency rate is only about 30%. For this reason, products that support the efficiency of forest quantity measurement have been put on the market with the aim of improving the profitability and cost reduction of timber production. However, these are still not widely used due to their inconvenience, and high price. This study proposed a system for measuring the amount of forest quantity focusing on standing timber using an estimation system based on EfficientNet-B0 from omnidirectional camera images. The usefulness of the proposed system was confirmed by the evaluation experiments.

Keywords forest measurement, deep learning, convolutional neural network, semantic segmentation, omnidirectional image.

1. はじめに

我が国の森林資源は成熟し、人工林の多くは本格的な利用期を迎えている。しかし、木材価格の低迷により、伐採にかかるコストを差し引くと、林業事業体は十分な収益が得られない場合が多く、国産材の需要に応じた安定的な原木供給ができない状況にある。また、木材生産の収益性向上、森林調査の省力化によるコスト削減を目指し、森林物理量の計測作業を効率化する製品が市場投入されているが、利便性や価格の面から普及するまでには至っていない。

当研究室では、多大な労力を要する森林調査の省力化、効率化を実現するため、林内全天球画像を対象に、“材積”および“丸太原木品質”の観点から、森林資源量を推定するシステムを提案してきた¹⁾。

本論文では、森林資源量をより質の観点からも高精度に推定可能とすることを旨とし、“材積”、“樹高”、“立木密度”、“胸高直径”、“胸高断面積合計”、“矢高”の6項目の森林物理量を推定する森林計測システムを提案する。

2. 森林計測システム

2.1 システム概要

図1に、提案システムの概要を示す。提案システムは、360°カメラで撮影した林内全天球画像(5376×2688画素)を224×224画素にリサイズした画像から、EfficientNet-B0²⁾を用いて森林物理量を推定する物理量推定モデルと、EfficientNet-B0を用いたエンコーダ・デコーダネットワークによってセマンティックセグメンテーションを実行し立木領域画像を生成する立木領域抽出モデルから構成される。立木領域抽出モデルで実現する機能は必ずしも必須ではなく、物理量推定モデル単体のみでも森林物理量の推定は実現できるが、立木領域抽出モデルを用いることで、林内全天球画像内の立木領域の情報を物理量推定モデルが活用できるようになるため、より高精度な森林物理量の推定が期待できる。なお、224×224画素にリサイズした

林内全天球画像を用いるのは、EfficientNet-B0のネットワーク構造が224×224画素のサイズの入力画像に最適化されているためである。

2.2 物理量推定モデル

物理量推定モデルはEfficientNet-B0を基に構成されており、その入力は、林内全天球画像(224×224画素)、または、林内全天球画像(224×224画素)と立木領域抽出モデルにより生成された立木領域画像を結合した画像であり、出力は、林内全天球画像の撮影地点から半径12.6m以内の森林物理量6項目の“材積”、“樹高”、“立木密度”、“胸高直径”、“胸高断面積合計”、“矢高”である。

2.3 立木領域抽出モデル

立木領域抽出モデルもEfficientNet-B0を基に構成されており、その入力は、林内全天球画像(224×224画素)であり、出力は、入力された林内全天球画像(224×224画素)の立木領域を“白”、立木以外を“黒”として画素ごとに示した立木領域画像(224×224画素)である。

3. 評価実験

提案システムの有用性を確認するため、石川県内の11地区、29林分、1514地点で撮影した4988枚の林内全天球画像と、それに紐づく森林物理量、正解立木領域画像からなるデータセットを用いて、物理量推定モデルのみ、立木領域抽出モデルのみの評価実験と、両モデルで構成した森林計測システムの評価実験を行った。

3.1 物理量推定モデル

EfficientNet-B0ベースの物理量推定モデルの有用性を評価するために、従来システムのDenseNet-201ベースの物理量推定モデルとの比較評価実験、およびEfficientNet-B0ベースの物理量推定モデルによる森林物理量6項目の推定精度の評価実験を行った。

まず、11地区29林分、1514地点の林内全天球画像とそれに紐づく“材積”のみからなるデータ4988組を用いて、




図1 森林計測システム
Fig.1 Forest measurement system.

EfficientNet-B0 と DenseNet-201 ベースの物理量推定モデルの比較評価実験を行った。EfficientNet-B0 ベースと DenseNet-201 ベースの物理量推定モデルの各々に、3531 組のデータを学習させ、1457 組のデータについて“材積”の推定精度を評価した。図 2 に推定値と正解値の散布図を示す。図中、実線は推定誤差 0%を、点線は中央から順に推定誤差 10%、20%を示している。EfficientNet-B0 ベースは、DenseNet-201 ベースに比べて、推定誤差 10%以内のデータ数の割合が 8%ほど高く、EfficientNet-B0 ベース物理量推定モデルの有用性が確認できた。

次に、11 地区 19 林分、500 地点の林内全天球画像とそれに紐づく森林物理量 6 項目からなるデータ 1636 組を用いて、EfficientNet-B0 ベースの物理量推定モデルによる森林物理量 6 項目の推定精度の評価実験を行った。物理量推定モデルに、1148 組のデータの林内全天球画像を左右反転、シフト変換でデータ拡張した 4592 組のデータを学習させ、488 組のテストデータで森林物理量の推定精度を評価した。図 3 に、各森林物理量の推定結果の散布図を示す。この結果から、各物理量の推定誤差はほとんどが 20% 以内であり、物理量推定モデルの有用性が確認できた。




図 2 2つの CNN モデルによる材積推定値の散布図
Fig.2 The scatter plots of timber volume estimation by DenseNet-201 and EfficientNet-B0.

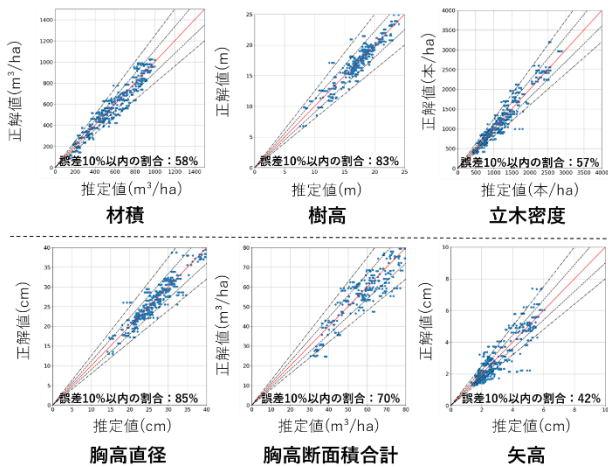


図 3 森林物理量推定結果の散布図
Fig.3 The scatter plots of forest quantity estimation results.

3.2 立木領域抽出モデル

立木領域抽出モデルの有用性を確認するため、11 地区 20 林分、432 地点の林内全天球画像とそれに紐づいた正解立木領域画像からなるデータ 432 組を用いて、評価実験を行った。432 組のデータを 5 つのサブセットに分割し、1 Fold ごとに 4 つのサブセット 345 組の林内全天球画像




図 4 立木領域抽出結果
Fig.4 The standing timber region extraction result.

をシフト変換で 224 倍にデータ拡張した 77280 組のデータを立木領域抽出モデルの学習データとして、1 つのサブセット 87 組をテストデータとして、k-分割交差検証法 (k=5)を適用し、すべての林内全天球画像の立木領域抽出精度を評価した。図 4 に、立木領域抽出結果の一例を示す。この結果から、林内全天球画像の立木領域がある程度抽出できており、立木領域抽出モデルによる立木領域抽出が可能であることを確認した。

3.3 森林計測システム

立木領域抽出モデルと物理量推定モデルの両モデルで構成した森林計測システムの有用性を評価するため、11 地区 29 林分、432 地点の林内全天球画像とそれに紐づいた“材積”，正解立木領域画像からなるデータ 432 組を用いて、評価実験を行った。物理量推定モデルに、388 組のデータを学習させ、44 組のテストデータについて森林物理量の推定精度を評価した。図 5 に、物理量推定モデルのみを用いた場合、3.2 で構築した立木領域抽出モデルを用いて推定した立木領域画像を結合した場合、立木領域抽出モデルは用いずに正解立木領域画像を結合させた場合の各々の材積推定結果の散布図を示す。立木領域画像を結合した場合は、結合しなかった場合に比べて、推定誤差 10% 以内のデータ数の割合が 8%ほど高く、立木領域抽出モデルの有用性、さらには、“材積”以外の森林物理量 5 項目についても同様に精度向上が期待できることから、提案システムの有用性が確認できた。また、正解立木領域画像を結合した場合は、推定した立木領域画像を結合した場合に比べて、推定誤差 10%以内のデータ数の割合が 10%ほど高く、立木領域抽出モデルの抽出精度が向上すれば、物理量推定モデルの推定精度も向上することが期待できる。今後は、立木領域抽出モデルの学習データ拡充による立木領域抽出精度の向上を図る。




図 5 物理量推定モデルの入力の違いによる材積推定値の散布図

Fig.5 The scatter plots of timber volume estimates for different inputs to the forest quantity estimation model.

4. おわりに

本論文では、林内全天球画像から森林資源量を質の観点からも高精度に推定できる森林計測システムを提案し、評価実験によりその有用性を確認した。今後も、評価・改良を継続し、実用的なシステムへと展開していきたい。なお、本研究は生研支援センター「イノベーション創出強化研究推進事業」の支援を受けて行ったものである。

参考文献

- [1] 林航希, 九後佑樹, 松井康浩, 長田茂美, 村上良平, 山路佳奈, 木村一也, 矢田豊, “深層学習に基づく全天球画像からの人工林材積・原木品質の推定技術の開発,” 第 132 回日本森林学会大会, S4-3, 2021.
- [2] Mingxing Tan, Quoc V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” arXiv:1905.11946, 2020.

本プロジェクトに関する業績

- 1) 林航希, 長田茂美, 松井康浩ほか, “深層学習に基づく森林画像認識システムの提案と評価,” 動的画像処理実利用化ワークショップ, 2022.