

テーマ番号	EP071			
プロジェクト テーマ	和文	深層学習を用いた全天球画像解析による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 Resource Measurement System by Omnidirectional Image Analysis Using Deep Learning		
プロジェクト メンバー	4EP2-37 根本 航介 (Kosuke Nemoto)			

Abstract 木材生産の収益性向上, コスト削減を目指して, 森林資源量の計測作業を効率化するための製品がいくつか開発されているが, 利便性や価格の面からまだ十分に普及するには至っていない. 本研究では, 誰もが手軽に利用でき, 廉価で高精度な森林資源量計測システムの実現を目的として, 全天球カメラにより撮影した森林の全天球画像を対象に, 深層学習の一種である畳み込みニューラルネットワークを用いて材積量を推定する森林資源量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.

Keywords forest resource measurement, deep learning, convolutional neural network, feature map, omnidirectional image.

1. まえがき

我が国の人工林の多くは今まさに収穫期を迎えているが, 昨今の木材価格の低迷により木材生産が進んでいないのが実状である. 木材生産の収益性向上, コスト削減を目指して, 森林資源量の計測作業を効率化するための製品もいくつか開発されているが, 利便性や価格の面からまだ十分に普及するには至っていない.

本研究では, 誰もが手軽に利用でき, 廉価で高精度な森林資源量計測システムの実現を目的として, 全天球カメラにより撮影した森林の全天球画像を対象に, 深層学習を用いて材積量を推定する森林資源量計測システムの開発を目指す.

2. システム概要

図 1 に, 提案する森林資源量計測システムの概要を示す. 深層学習の一種である畳み込みニューラルネットワーク(CNN, Convolutional Neural Network)^[1]を 2 段に配置し, 5376×2688 画素の原画像を 256×128 画素に正規化した全天球画像をその材積量に応じて, まず, 一段目の CNN で大分類を行い, 次に, その分類結果に基づいて, 二段目の CNN でさらに詳細分類するという構成を採っている. 図 2 に, 本システムで用いる CNN の構造を示す.

2.1 システム開発上の課題

実用的なシステム性能要件として, 100~1500m³/ha の範囲の材積量を 10m³/ha の分解能で推定することが要求される. この要求仕様を充たすためには, 100~1500m³の材積量の範囲をカバーする膨大な量の学習データセット(材積量が既知の全天球画像群)を収集する必要があるが, それを現実的に実現するのは極めて難しい.

そこで, 本研究では, 限られた量の学習データセットを用いて高精度な森林資源量計測システムを実現するために, データ拡張(Data Augmentation)および CNN の最適なフィルターサイズの検討を行った.

2.2 データ拡張

全天球画像は, 周囲 360 度のすべての方向に亘って撮影された画像であり, 全天球画像の画素列を左右方向にシフトすることで, 新たな全天球画像を生成することができる. 本システムでは, 画素列のシフト操作と画像のガンマ補正によって, データ拡張を実現し, 全天球画像の多様性を増加させている.

2.3 最適なフィルターサイズの検討

フィルターとは, CNN の畳み込み層で用いる畳み込みフィルターのことであり, 樹木の特徴をよりの確に捉え, 精度向上を図るためには, フィルターサイズの最適化が必要である. 本システムでは, CNN への入力として, RGB

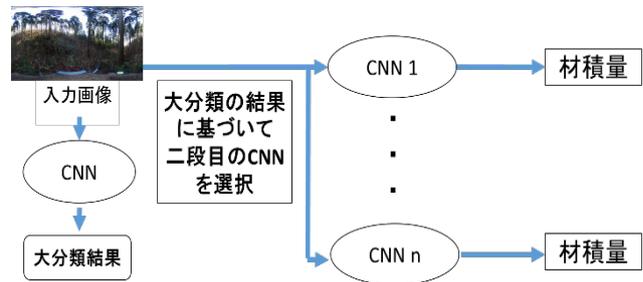


図1 提案システムの概要

Fig. 1 Overview of the proposed system.

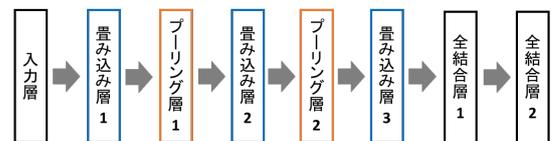


図2 CNN の構造

Fig. 2 The structure of CNN.

の 3 チャンネルのカラー全天球画像を用いており, すべてのチャンネル, すべての畳み込み層のフィルターとしては, 同一サイズのものを用いている.

3. システム評価

3.1 評価実験

評価実験では, 25 種類の材積量が既知の全天球画像群を学習データセットとして, また, 学習データセットとして使用していない 20 種類の材積量が既知の全天球画像群をテストデータセットとして使用した. 学習データセットを用いて CNN の学習済モデルを作成した後に, 一段目の CNN で 5 種類の材積量に対応したカテゴリに大分類を行い, その大分類結果に基づいて, さらに, 二段目の CNN で 5 種類の材積量に対応したカテゴリに詳細分類を行った. 表 1 に, 評価実験で用いた学習データセット用の全天球画像群の 25 種類のカテゴリ毎の材積量を示す.

3.2 データ拡張

まず, 学習データセットのデータ拡張の効果を確認するために, DS_orig, DS_da の 2 種類の学習データセットを作成し, 分類精度の評価実験を行った. D_orig は, 全天球カメラで撮影した 100 枚の全天球画像の原画像群であり, DS_da は, DS_orig の全天球画像を基に, シフト操作およびガンマ補正によってデータ拡張を行った学習データセットである.

表1 材積量

Table 1 Wood material quantity.

大分類 No.	詳細分類 No.	材積量 (m ³ /ha)	大分類 No.	詳細分類 No.	材積量 (m ³ /ha)
1	1	163	3	14	598
	2	193		15	632
	3	236	4	16	652
	4	266		17	668
	5	306		18	671
2	6	350	5	19	691
	7	367		20	834
	8	414	5	21	919
	9	452		22	939
	10	468		23	1065
3	11	508	5	24	1170
	12	528		25	1561
	13	553			

表2 評価実験結果(データ拡張)

Table 2 Result of evaluation experiment (variety).

学習データセット	正解枚数	正解率
DS_orig	36/200	18.0%
DS_da	179/200	89.5%

表3 評価実験結果(フィルターサイズの最適化)

Table 3 Result of evaluation experiment (optimization of the filter size).

フィルターサイズ	正解枚数	正解率
8×8	179/200	89.2%
10×8	188/200	94.0%

3.3 最適フィルターサイズの検討

最適な CNN のフィルターサイズを検討するために、7種類のサイズのフィルターを用いた場合の分類精度の評価実験を行った。学習データセット DS_da を用いて、7種類のフィルターサイズの各々に対応した CNN の学習済みモデルを作成し、テストデータセット DS_test を用いて、分類精度を評価した。表 3 に、8×8、10×8 の2種類のフィルターサイズを用いた場合の分類精度を示す。また、図 4 に、2種類のサイズのフィルターを用いた場合の畳み込み層 1 から生成した特徴マップを示す。10×8 のサイズのフィルターは、樹木の特徴をよりの確に捉えることができ、分類精度を向上できたものと考えられる。

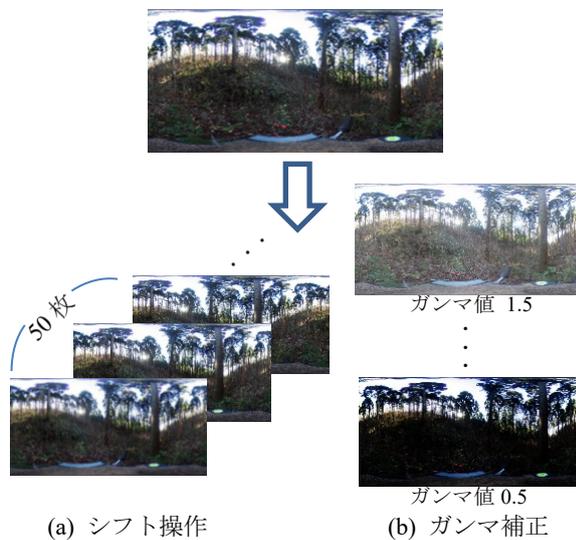
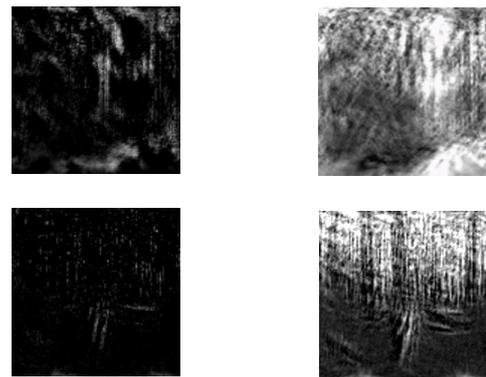


図3 データ拡張
Fig. 3 Data augmentation.

シフト操作によるデータ拡張では、DS_orig の 1 枚の 5376×2688 画素の全天球画像の原画像に対して、5376/50 画素列ずつ左方向にシフトする(左に溢れた画素列は画像の右側に追加する)操作を 50 回繰り返すことによって、50 枚の新たな全天球画像群を生成した。また、ガンマ補正によるデータ拡張では、1 枚の全天球画像に対して、0.5～1.5 の範囲の 11 種類のガンマ値を用いてガンマ補正を施し、11 枚の新たな全天球画像群を生成した。したがって、本システムでは、シフト操作およびガンマ補正によるデータ拡張で、DS_orig の 1 枚の全天球画像から、50×11=550 枚の全天球画像群を生成できる。

図 3 に、データ拡張により生成された全天球画像群の例を示す。DS_orig は 100 枚、DS_da は 5500 枚の全天球画像群である。テストデータセット DS_test としては、20 種類のカテゴリごとに、学習データセットのデータ拡張で用いていないシフト操作およびガンマ補正により生成した 10 枚の全天球画像群を使用した。表 2 に、DS_orig、DS_da の 2 種類の学習データセットの各々を用いて学習させた CNN の学習済みモデルに、テストデータセット DS_test を与えたときの材積量の分類精度を示す。

シフト操作およびガンマ補正によるデータ拡張を行い、学習データセットの多様性を増すことで、CNN が材積量と密接な関連をもつ本質的な画像特徴を捉えることができ、分類精度を向上できたものと考えられる。



(a) フィルター(8×8) (b) フィルター(10×8)

図4 特徴マップ(畳み込み層 1)
Fig. 4 Feature maps (convolution layer 1).

4. むすび

本研究では、森林の全天球画像から、深層学習を用いて、その材積量を推定する森林資源量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、学習データセットの拡充、評価・改良を継続し、精度向上を図っていく予定である。最後に、多大なるご支援を頂いている石川県農林総合研究センターならびに(株)エイブルコンピュータの関係各位に感謝いたします。

参考文献

- [1] 岡谷貴之, “ディープラーニングによる画像認識,” 情報処理学会誌, 56(7)号, 2015.
- [2] 斎藤康毅, ゼロから作る Deep Learning, オライリージャパン, 2016.

本プロジェクトに関する業績

- 1) 根本航介, 川崎邦将, 松井康浩, 長田茂美, 寺本誠, 矢田豊, “深層学習を用いた全天球画像解析による森林資源量計測システムに関する研究,” 第 7 回中部森林学会大会, 510, 2017.