

UAV-LiDAR 計測による高密度点群を用いた深層学習による スギ樹冠抽出手法の開発^{*1}

相原直生^{*2}・光田 靖^{*3}

相原直生・光田 靖：UAV-LiDAR 計測による高密度点群を用いた深層学習によるスギ樹冠抽出手法の開発 九州森林研究 77：83－86, 2024 本研究では、三次元点群データに適用可能な深層学習モデルを用いて、UAV-LiDAR により計測した高密度点群から三次元のスギ樹冠抽出を行った。事前に樹頂点検出を行い、樹頂点を中心とした 6×6 m のサンプル領域に含まれる点群を判別対象として抜き出し、中心とした樹頂点を含む個体に属する点群を樹冠として判別した。出力された予測の精度評価を行った結果、サンプル領域のデータ内に 1 本の立木のみがある場合は高い精度で樹冠を抽出できた。しかし、サンプル領域内に複数の立木がある場合は、全ての樹冠を完全に抽出することはできなかった。

キーワード：UAV-LiDAR, 樹冠, 深層学習

I. はじめに

樹冠情報は森林の成長量と密接に関連しており、成長予測に重要な情報である（例えば、梶原, 1985; 吉田, 1991）。そのため、空中レーザにより取得した点群を用いて樹冠抽出を試みた研究は多く存在する（例えば、松英ほか, 2006）。多くの先行研究では、三次元点群データを Digital Surface Model (DSM) や Canopy Height Model (CHM) といった二次元データに変換し、樹冠抽出および樹冠サイズ推定を行っている。しかし、こういった手法では、点群データが持っていた大量の情報が失われ、樹冠に関する解析が制限されてしまう。

最近では、深層学習モデルの一つである PointNet (Qi *et al.*, 2017) が開発されたことで、三次元点群データをそのまま用いた物体の判別が可能になった。このような深層学習モデルを使用することで、情報を消失しない樹冠抽出を行うことが期待できる。いくつかの先行研究において、深層学習モデルを用いて、広域調査地の三次元点群データから様々な樹種の各立木樹冠の識別を行っている（例えば、Windrim and Bryson, 2020; Chen *et al.*, 2021）。しかし、これらの手法では、ボクセル化により点群の情報が失われていることに加え、DSM などの二次元データも使用している。加工を施していない三次元点群データと深層学習モデルのみを用いて、スギ樹冠抽出を行った事例は存在しない。よって、本研究では、三次元点群データに適用可能な深層学習モデルを使用したスギ樹冠抽出モデルを開発し、その精度を評価することを目的とした。

II. 調査地と方法

調査地は宮崎県宮崎市高岡町の 56 年生のスギ人工林（以下、高岡）と田野町に位置する宮崎大学田野フィールド内の 47 年

生と 58 年生のスギ人工林（以下、田野）とした。使用した点群データは、DJI 社の Matirice 300 RTK にレーザスキャナである Zenmuse L1 を搭載した UAV による計測により取得した。表-1 に計測した点群の詳細を示す。

表-1. 各調査地で行った計測

	高岡	田野
計測日	2023 / 5 / 15	2023 / 7 / 14
計測面積	47 ha	5 ha
飛行高度	100 m	80 m
点群密度	752.1 points/m ²	1016.9 points/m ²
オーバーラップ率	90 %	90 %
サイドラップ率	80 %	80 %

取得した点群は、計測時のノイズを除去するために、ある点と複数の近傍点との距離が閾値以上であれば、ある点を除去する Statical Outlier Removal を実行した。次に樹頂点を検出するために Local Maximum フィルタ（検索範囲 5 m）を実行した (Popescu *et al.*, 2002)。この樹頂点を中心に、6×6 m のサンプル領域を作成した。このサンプル領域内にあるスギ樹冠にラベル付けするため、目視で樹冠・非樹冠点群を判別して学習および検証データを作成した。その際、サンプル領域を①完全な形をした樹冠が一つだけ含まれているブロック（以下、単木ブロックとする）と、②中心とした個体だけでなく隣接木の樹頂点を含む樹冠が複数含まれているブロック（以下、複数木ブロックとする）の二つの型に区分した（図-1）。

本研究では、深層学習モデルとして Kernel Point Convolution (KPCConv; Thomas *et al.*, 2019) を使用した。KPCConv は、ある

^{*1} Aihara, N. and Mitsuda, Y. : Development of *Cryptomeria japonica* canopy extraction method using deep learning with high point density points cloud measured by UAV-LiDAR.

^{*2} 宮崎大学大学院農学研究科 Grad. Sch. Agric., Univ. Miyazaki 889 - 2192, Japan

^{*3} 宮崎大学農学部 Fac. Agric., Univ. Miyazaki, 889 - 2192, Japan

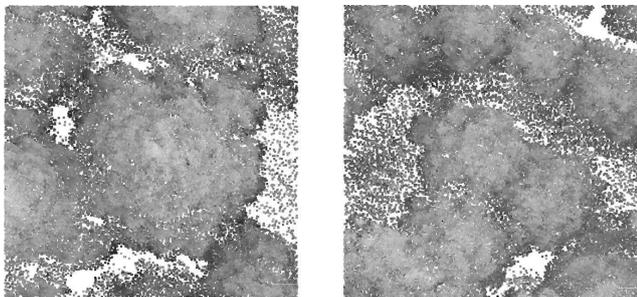


図-1. 単木ブロック (左) と複数木ブロック (右) の例

点を中心とした球体に含まれた全ての点に対して、重みが適用され、畳み込みを行うことで特徴を抽出する。特徴量は、点の座標と色である赤、緑、青の値を使用した。学習データは高岡から取得した 640 個の単木ブロックを使用した。検証データには、それぞれの調査地から単木ブロックを 35 個、複数木ブロックを 15 個を使用した。学習パラメータは、Thomas *et al.* (2019) が設定したものを使用した。この時、データ容量の問題から 640 個のデータを一度に学習することができなかつたため、160 個ごとに 250 エポックの学習を 4 回行った。一連の深層学習の実行には、GPU として NVIDIA RTX GeForce 3060 Ti (8 GB) を使用し、python 3.7 と pytorch 1.12 で実行した。

精度指標は値が大きいほど予測の見落としが少なくなること示す Recall (r) (1)、値が大きいほど誤検知が少なくなること示す Precision (p) (2)、 r と p の調和平均である F (3)、大きいほど正解と予測の樹冠の領域が重なっていることを示す Intersection over Union (IoU) (4) の 4 つを採用した。これらの指標は以下の式で計算される。

$$r = \frac{TP}{TP + FN} \quad (1)$$

$$p = \frac{TP}{TP + FP} \quad (2)$$

$$F = 2 \times \frac{r \times p}{(r + p)} \quad (3)$$

$$IoU = \frac{|true \cap pred|}{|true \cup pred|} \quad (4)$$

ここで、TP は正解と予測が一致した点数、FN は正解が樹冠であるのに非樹冠と予測された点数、FP は正解が非樹冠であるのに樹冠と予測された点数、 $|true \cap pred|$ は正解と予測の樹冠領域の重なっている面積、 $|true \cup pred|$ は正解と予測の樹冠領域の合計面積を示している。さらに、予測の傾向を調べるために、結果を 5 つの類型に目視で分けた (表-2)。また、モデルの解釈

表-2. 予測傾向の類型

類型	結果の説明
良質	正解をほとんど再現できている
無視	存在するはずの樹冠を無視している
欠落	予測した樹冠の一部が欠如している
一部のみ予測	樹冠の一部のみを予測している
分散	予測がまとまっていない

を深めるため、モデルが注目している領域を可視化する Grad-cam (Selvaraju *et al.*, 2017) を利用した。

Ⅲ. 結果

表-3 に精度評価の結果を示した。単木ブロックと複数木ブロックの精度を比較すると、田野の p 以外は、全て単木のほうが大きい値であり、標準偏差も小さかった。高岡と田野の単木ブロック及び複数木ブロックの p , F , IoU を比較すると大きな差はなかった。しかし、 r の差については、高岡では単木ブロックが 91.3% に対して複数木ブロックが 61.8%、田野では単木ブロックが 93.9% に対して複数木ブロックが 54.1% となっており、両調査地共に 30 ポイント弱以上の差があった。

予測に対する目視評価の傾向を図-2 に示す。両調査地共に、単木ブロックの予測は 90% 以上が「良質」であることが分かった。一方で、複数木ブロックにおける予測では、「良質」は存在せず、60% ほどが「無視」の類型であり、次に「一部のみ予測」が占めていることが分かった。単木ブロックの予測傾向のほとんどを占める「良質」の類型では、モデルが一つの樹冠に注目を集めていることが分かった (図-3)。しかし、それ以外の類型に関しては、注目すべきではない領域の注目度が高くなっている他、注目すべき領域に注目していないことが傾向として見受けられた (図-4 から 7)。

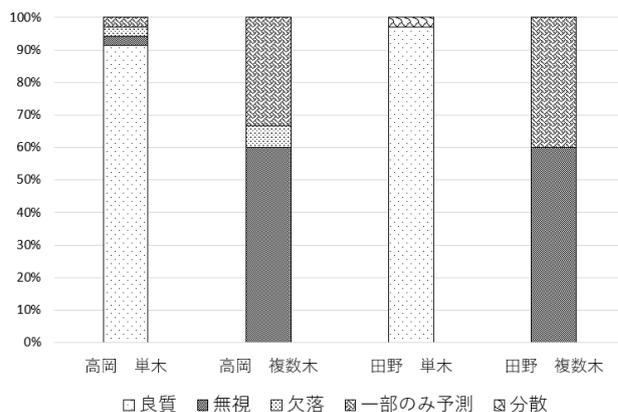


図-2. 予測傾向の割合

Ⅳ. 考察

本研究の結果から、三次元点群データに適用可能な深層学習モデルを用いることで情報を失わずに三次元データとしてスギ樹冠の抽出が可能であることが示された。さらに、Grad-cam により、深層学習モデルが注目している領域を可視化することができた (図-3 から 7)。ブロック内に単木のみが存在する場合には、その樹冠に注目が集まり、正解と近い樹冠を抽出していることが分かった。他方で、ブロック内に複数の樹冠が存在する場合、一つの樹冠に注目が集まるが他の樹冠には集まらず、複数ある樹冠を見落とす予測傾向が見受けられた。最も大きな原因として、単木のみを深層学習モデルに学習させたことが挙げられ、ブロック内にある樹冠を一つだけ抽出できるモデルが構築されたと考えられ

表-3. 両調査地の各ブロック型の精度値 (%) (±標準偏差)

調査地	ブロック型	r (%)	p (%)	F (%)	IoU (%)
高岡	単木 (n=35)	91.3 (± 6.0)	94.8 (± 5.7)	92.8 (± 4.1)	73.7 (± 15.7)
	複数木 (n=15)	61.8 (± 14.1)	94.6 (± 7.5)	74.0 (± 11.8)	61.8 (± 16.0)
田野	単木 (n=35)	93.9 (± 3.3)	97.5 (± 3.9)	95.7 (± 2.8)	77.5 (± 12.2)
	複数木 (n=15)	54.1 (± 15.1)	98.7 (± 2.5)	68.6 (± 13.3)	53.2 (± 19.1)

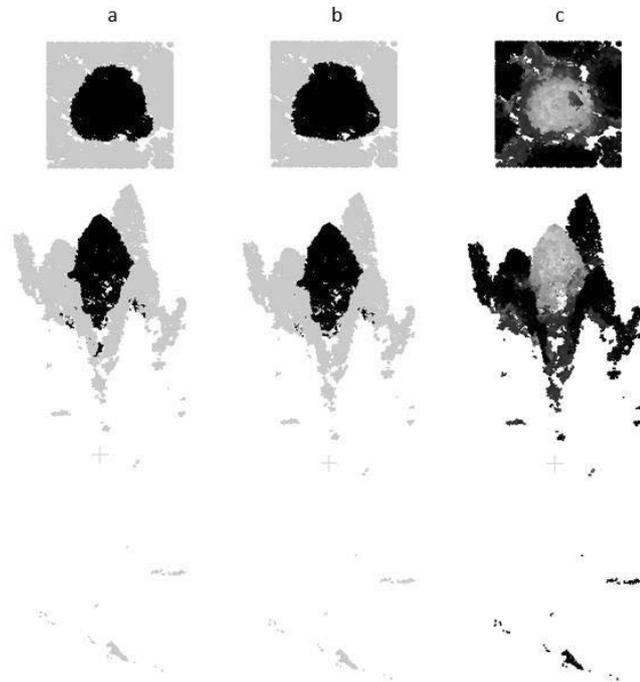


図-3. 「良質」の例 (a: 正解, b: 予測, c: Grad-cam)
a と b は、黒い領域が樹冠。c は、白くなるほど注目度が高い。

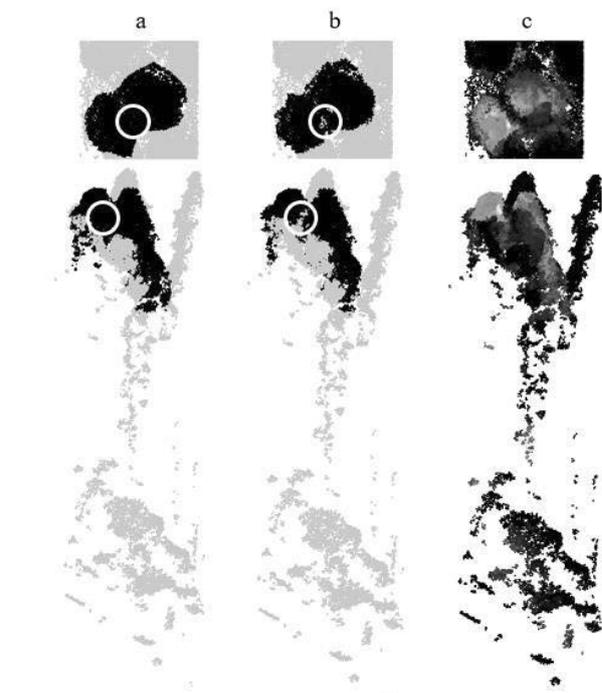


図-5. 「欠落」の例 (a: 正解, b: 予測, c: Grad-cam)
a と b は、黒い領域が樹冠。c は、白くなるほど注目度が高い。
丸で囲まれている部分は予測の欠落が生じている部分を示す。

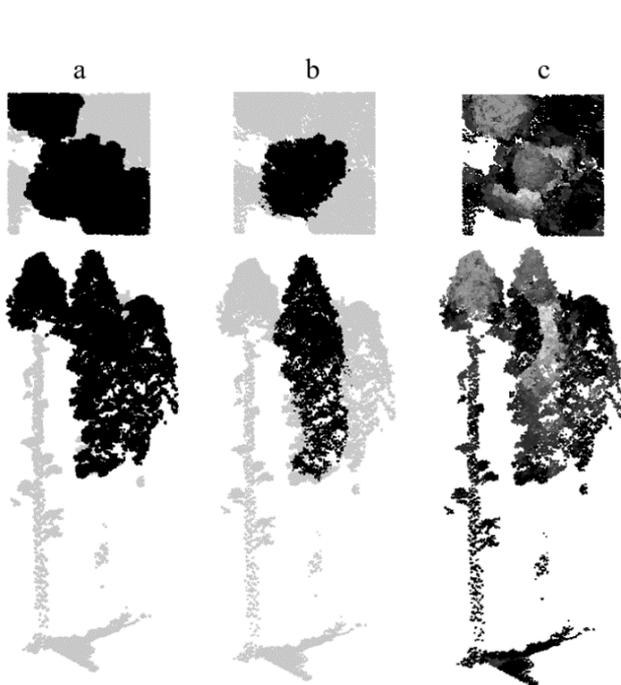


図-4. 「無視」の例 (a: 正解, b: 予測, c: Grad-cam)
a と b は、黒い領域が樹冠。c は、白くなるほど注目度が高い。

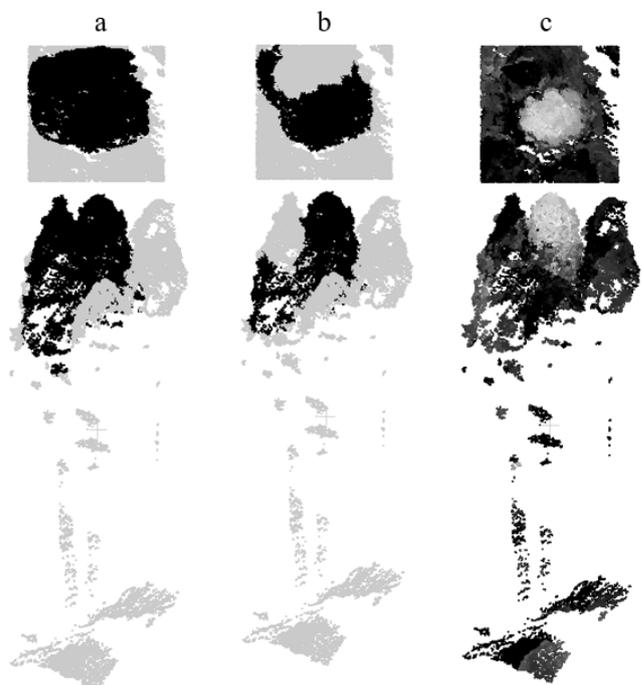


図-6. 「一部のみ予測」の例 (a: 正解, b: 予測, c: Grad-cam)
a と b は、黒い領域が樹冠。c は、白くなるほど注目度が高い。

る。この問題に対処するためには、一定サイズのブロックではなくブロックサイズを変化させて試行するアルゴリズムの使用または、学習データを変更するなどの方法が考えられる。より柔軟性および汎用性の高い深層学習モデルの作成については、今後、検証を重ねる必要がある。

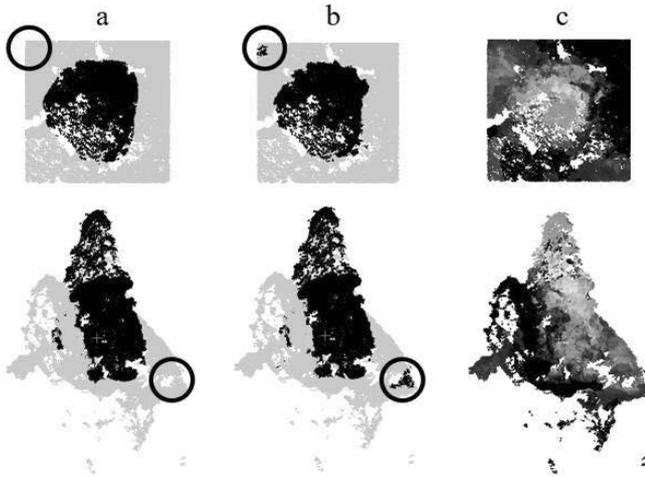


図-7. 「分散」の例 (a: 正解, b: 予測, c: Grad-cam)
 a と b は、黒い領域が樹冠。c は、白くなるほど注目度が高い。
 丸で囲まれている部分は予測の分散が生じている部分を示す。

V. 謝辞

本研究を行うにあたって JSPS 科研費 21K18226 の助成を受けた。ここに深く感謝申し上げます。

引用文献

- Windrim and Bryson (2020) Remote Sensing: 12 (9), 1469
 Chen *et al.* (2021) Forests: 12 (2), 131
 梶原幹弘 (1985) 日林誌: 67 (12), 501 - 505
 松英恵吾ほか (2006) 写真測量とリモートセンシング: 45 (1) 4 - 13
 Popescu S C *et al.* (2002) Comput. Electron. Agric: 37 (1 - 3), 71 - 95
 Qi C R *et al.* (2017) ICVV: 652 - 660
 Selvaraju R R *et al.* (2017) ICCV: 618 - 626
 Thomas H *et al.* (2019) ICCV: 6411 - 6420
 吉田茂二郎 (1991) 日林誌: 73 (1), 29 - 33
 (2023 年 11 月 10 日受付; 2023 年 12 月 12 日受理)