

# TLS 点群を用いた樹木形質の抽出と評価

電気通信大学 ○江藤 信輔, 増田 宏

## 1. 序論

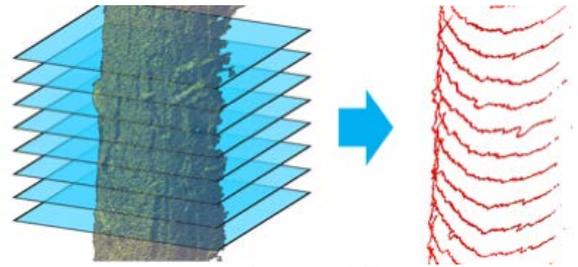
近年、レーザスキャナにより取得した点群を用いたデータ処理は、その効率性から様々な分野で注目されている。

森林研究において、樹木の遺伝子と形質との関係性の把握は重要な課題であるが、そのためには大量の樹木の遺伝子データおよびそれに対応するバイオマスパラメータが必要となる。従来行われていた手動によるバイオマスパラメータの計測には、膨大な時間と多大なコストを要するという問題があった。また、計測者によって形質評価に差異が生じることや、高所の計測には樹木の伐採が必要となることなどから、同一の樹木での継続的な計測が難しいという問題もあった。そこで、これらの問題解決のために、地上型レーザスキャナ(TLS)で取得した 3 次元点群を用いて、樹木の形質パラメータを算出することを考える。

本研究では、点群から大量の樹木形質を高精度に取得する方法について検討する。形質を正確に取得するためには、点群から樹木の幹、葉、枝を適切に分離することが必要である。本稿では、機械学習を用いて樹木を要素ごとに分離する手法について検討する。また、取得したデータの精度についての評価も行う。



(a) 地面点の除去



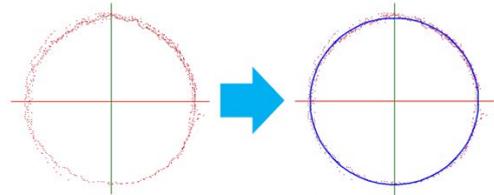
(b) 断面点の取得

## 2. 幹点群の分離

樹木の要素のうち、幹と枝は形状および材質が似ているため、機械学習による正確な分離が困難である。そこで、機械学習を用いる前にあらかじめ幹の点群のみを分離しておくことを考える。

我々はこれまでに、森林の大規模点群から幹を検出する手法を開発した[1]。本研究では、その手法を用いることにより幹点群を分離することを考える。

はじめに、幹の検出手法について説明を行う。幹の検出においては、まず点群における地面モデルを生成し、その付近の点を地面点として除去をする。次に点群全体を等間隔な水平面で切断して断面点を取得し、その断面点から円もしくは楕円を幹の断面形状として検出する。それらのうち一定条件を満たすもの同士を線形補間を用いて繋げることで幹を検出する。これらの手順をまとめたものを図 1 に示す。



(c) 断面形状の検出



(d) 幹の検出

図 1 幹の検出手順

次に、検出した幹に対して、幹点群の分離を行う。まず、幹の検出に使用した断面形状を用いて、幹周辺の点群を円筒座標に変換する。円筒座標は幹の軸を  $z$  軸、幹の中心軸からの距離を  $r$  軸、一定方向からの角度を  $\theta$  軸として定義される。円筒座標への変換を図 2 に示す。点群を円筒座標へ変換することにより、幹の点群は他の要素の点群と比較して  $r$  の値が小さくなる。その性質を用いることにより、円筒座標において図 1(a)と同じ方法で幹点群の分離が可能となる。そのようにして幹の点群を分離した様子を図 3 に示す。

## 3. 機械学習による枝葉の分類

本手法では、円筒座標へ変換し幹点群の分離を行った点群データに対して、機械学習による手法 Random Forest (RF) および  $k$ -means 法を用いて樹木要素の分類を行う。機械学習による分類では、枝と葉を分類することを目的とする。

### 3.1 特徴量の抽出

本手法では、点群の各点において、周辺点群を用いて主成分分析を行うことで 3 個の固有値を計算し、その値を特徴量として用いる。主成分分析は、注目点からそれぞれ 5cm, 7.5cm, 10cm, 15cm, 20cm 以内の距離にある点を用いて行った。また、枝と葉の表面の反射特性を利用するために、点の持つ反射強度の値も特徴量として用いた。そうして得られた 15 個の固有値および反射強度の計 16 個の値を、RF と  $k$ -means 法に用いる特徴量とする。

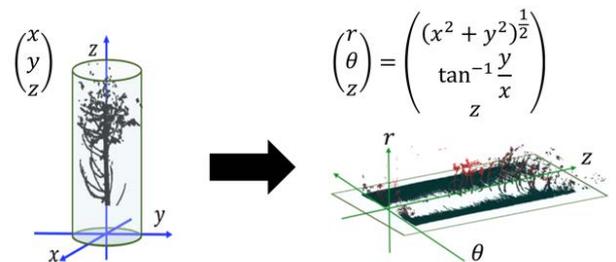


図 2 円筒座標への変換

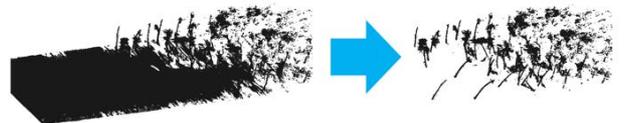


図 3 幹点群の分離

### 3.2 k-means 法による分類

k-means 法とは教師なし学習の手法であり, k 個のクラスターにデータを分類することができる. k-means 法の手順は, 以下に示す通りである.

- (1) 特徴量を持った点に対してランダムにクラスターを割り振る.
- (2) 特徴量を用いて各クラスターにおける中心を計算する.
- (3) 各点を最も近い中心のクラスターに再分類する.
- (4) クラスターの中心の変化がなくなるまで手順(2)(3)を繰り返す.

### 3.3 RF による分類

RF は教師あり学習のため, 教師データを作成する必要がある. そのため, 幹点群の分離を行った樹木点群に対して, 手動により点群の分類を行った. その分類結果と抽出した特徴量を用いて学習を行い RF による分類器を作成した. 学習に使用した教師データを図 4 に示す. ここでは, 葉を赤で示している.

RF では, 特徴量の重要度を算出することができる. 各特徴量の重要度を表 1 に示す. ここで,  $rcm(n)$  は, 半径  $rcm$  以内の点群による第  $n$  主成分の固有値を示す.



図 4 RF 教師データ

表 1 RF モデルにおける各特徴量の重要度

順位	特徴量	重要度(%)	順位	特徴量	重要度(%)
1	反射強度	39.050	9	5cm (3)	1.972
2	10cm (3)	14.758	10	10cm (1)	1.880
3	15cm (3)	11.504	11	5cm (1)	1.775
4	7.5cm (3)	7.283	12	7.5cm (1)	1.607
5	15cm (1)	6.117	13	15cm (2)	0.907
6	20cm (1)	5.430	14	10cm (2)	0.607
7	20cm (3)	4.435	15	5cm (2)	0.038
8	20cm (2)	2.628	16	7.5cm (2)	0.007

### 3.4 分類結果

円筒座標変換後の樹木点群に対して, RF および k-means 法を用いて機械学習による分類を行った. その結果を図 5 に示す. また, 正解率を表 2 に示す. ここでは, 手動により分類を行った結果を正解とした. また, 図 5 の青枠で囲まれた箇所を分類結果を図 6 に, 緑枠で囲まれた箇所を分類結果を図 7 に示す.

図 5 および表 2 から, k-means 法を用いたものと比べて RF を用いたもののほうが枝と葉の両方で精度が高くなっていることが確認できる. 図 6 と図 7 ではそれぞれ枝と葉の詳細な分類結果を示している.

## 4. 考察

RF を用いた機械学習では, 精度の高い分類が可能であることが確認できた. しかし, RF を用いるためには対象の樹種ごとの教師データが必要となるため, 可能であれば教師なし学習による手法を用いることが望ましい. 一方で, 今回用いた k-means 法による学習は教師なし学習であるが, その精度は RF と比較して低かった. 原因としては, 枝を葉と認識するものについては, 枝の端の点を中心とした主成分分析において, 枝の真ん中の点を中心としたものと固有値の差が出てしまうことだと考えられる. また, 葉を枝と認識するものについては, その箇所の反射強度を確認したところ, 葉の点が枝に近い反射強度であったため, k-means 法による学習では反射強度の重要度が必要以上に高くなってしまったことが原因と考えられる. k-means 法の精度向上のためには, 機械学習を行う前のデータに対して前処理を行うことや, 認識のた

めの特徴量を追加するなどの方法が考えられる. また, k-means 法以外の教師なし学習法が有効となる可能性もあるので, 他の手法についても検証を行っていく必要がある.

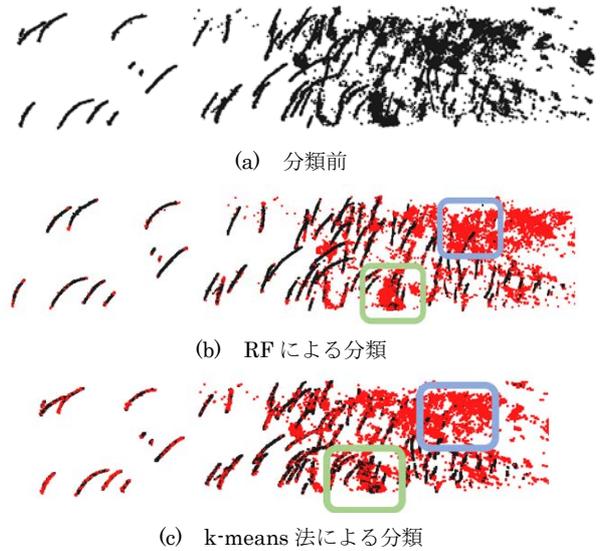


図 5 機械学習による分類結果

表 2 機械学習の正解率

	枝 (計 159941 点)	葉 (計 42465 点)
RF	87.95%	92.22%
k-means 法	82.24%	77.64%

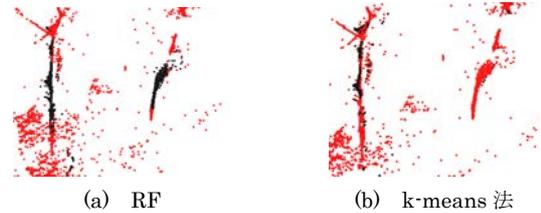


図 6 枝の認識

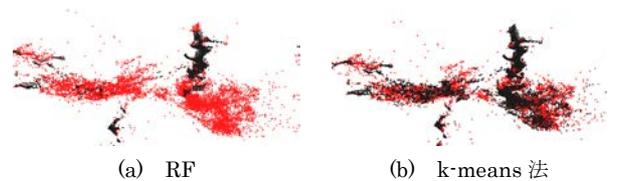


図 7 葉の認識

## 5. 結言

本研究では, 機械学習を用いて樹木の点群を幹, 枝, 葉に分離するための手法を提案した. 樹木要素の分離のために, まず樹木の円筒座標展開を用いて幹の点群を分離し, その後に機械学習を適用した. このとき, 機械学習における手法は Random Forest および k-means 法を使用した. 今後は, k-means 法を用いた学習の精度向上のために, 使用するパラメータの再検討をする必要がある. また, k-means 法以外の教師なし学習についても検証を行っていく.

## 参考文献

- [1] 齋藤 和人, 増田 宏: 三次元点群に基づく樹木の形状再構成第 3 報, 精密工学会秋季講演会 2016