

機械学習を用いた移動計測点群データの分類

電気通信大学 ○深野 健太, 増田 宏

Classification of the point-cloud data by the mobile mapping system with the machine learning

The University of Electro Communication: Kenta Fukano, Hiroshi Maeda

Point-clouds captured by a MMS are useful for maintenance of infrastructures, such as road signs, utility poles, and signals. In many applications, it is necessary to segment a point-cloud into features and to identify feature types of each point-set. In our previous research, we proposed a method for classifying features by using the Random Forest. In this paper, we extend our method by applying surface extraction of cylinders and planes, and try to improve the reliability of classification.

Key words: point-clouds, MMS

1. 緒 言

道路周辺の3次元情報は、標識や信号機のような社会的インフラのメンテナンスや自動車の安全性向上などに利用することができる。この3次元情報の取得には、移動計測による点群データが有効である。移動計測では自動車にGPS, IMU, レーザースキャナ, カメラを搭載し、走行させることで道路周辺の点群データを計測する。

しかしながら移動計測点群データは膨大な量の地物の点群を含んでいるため、それらの地物を抽出し、種類ごとに正しく分類することが、多くの応用システムで必要となる。前回の研究では、移動計測により得られた点群データから、機械学習法を用いて地物点群を自動分類し、3次元情報を取得する手法を提案した。しかしながら、信号など高い認識率が得られなかった地物も存在した。今回は、我々の手法に、曲面のセグメンテーション手法を組み合わせて、認識率を向上させることを考える。



Fig.1 Mobile Mapping System

2. 手法の概要

本手法では図1に示すMobile Mapping System(MMS)を用いて計測を行う。今回使用したMMSでは、合計4つのレーザースキャナを搭載し、上方と下方の点群をそれぞれ2つずつ計測する。この点群データから、電柱、ガードレール、街灯、標識、信号機、木の6つを分類対象として抽出することを考える。

具体的な手順としては、文献[2]の手法で点群データから路面の点群を除去し、互いに近傍な点を検出し連結させて地物成分を作成する。また、点群から円柱と平面を検出して、それらを分離する。その後、地物成分から特徴量を計算し、機会学習法としてRandom Forest法[1]を用いて地物の分類をおこなう。

3. 地物の分類手法

3.1 Random Forest 法

Random Forest法は機械学習法の1つであり、識別や、回帰に用いられる手法である。特徴量をパラメータとした学習データからランダムに変数を選択して、複数の決定木を作成するアルゴリズムである。

このRandom Forest法は機会学習法の中でも、精度が高くない複数の結果を組み合わせることで最終的に精度を向上させる集合学習法に分類される。特徴として、ほかの手法よりも計算速度が速く、外れ値やノイズに対して比較的強いなどが挙げられる。

MMSにより計測された点群データはノイズや欠落箇所を多く含んでいるため、様々な機械学習法の中でもこの手法は特に適用であると考えられる。

3.2 点群のセグメンテーション

点群を各地物ごとにグルーピングするために、ある閾値(ここでは35cm)を設定し、その値より点の間隔が小さい点を、距離に近い順にk個連結したk-近傍グラフを作成する。近傍点の探索にはkd-treeを用いている。次に、k-近傍グラフを連結成分の集合に分離する。連結成分に含まれる点の個数が閾値(ここでは30個)より小さい連結成分はノイズとして除去する。

本研究ではこの連結成分から、さらに円柱と平面部分を分離して、機械学習のための特徴量の計算に利用する。

円柱部分の抽出にはRANSAC法による円弧の検出を用いる。この方法では、最初に点群をZ軸方向に投影し、点密度の高い部分を検出する。点の高密度部分の検出にはドローネ分割を用いた。ドローネ分割では、ある閾値(ここでは3cm)より大きいエッジを持つ三角形は除去する。最終的にできた連結成分内の点数が30個以上であった場合、それを高密度部分とみなす。この部分にRANSAC法を用いて円弧部分を検出する[3]。ただし、円弧と見なしたとしても、元の高さが80cm以下の場合は除外する。なお、複数の円柱が検出された場合は、複数の地物が混在した点群と看做し、今回の研究では分類の対象から除外した。

平面部分の検出についても RANSAC 法を用いる。任意に 3 点を選び、それらを通る平面式を計算して、平面からの距離が閾値(ここでは 5cm)以内にある点数を計算する。次に、k-近傍グラフの連結性を調べ、平面上の点の集合から最大連結成分を求める。この操作を繰り返して、最大連結成分が最も大きくなる平面を求める。なお、最大連結成分の点の個数が閾値(ここでは 100 個)に満たない場合は、平面部が存在しないものと見なす。

3.3 抽出する特徴量

以下に研究で用いた特徴量 f1~f21 を示す。f1~f9 は点群全体に関する特徴量, f10~f12 は円柱部を除いた場合の特徴量, f13~f18 は円柱部に関する特徴量, f19~f24 は平面部に関する特徴量である。

1. f1~f3: 点群の大きさ(X, Y, Z)
2. f4~f6: 主成分分析の固有値($\lambda_1, \lambda_2, \lambda_3$)
3. f7~f9: 主成分分析による固有値の比($\lambda_1/\lambda_2, \lambda_2/\lambda_3, \lambda_1/\lambda_3$)
4. f10~f12: 円柱部分除去後の主成分分析の固有値
5. f13~f15: 円柱抽出後の点群の大きさ(X, Y, Z)
6. f16~f18: 円柱部分の大きさ(X, Y, Z)
7. f19~f21: 円柱部分と円柱除去部分の大きさの比
8. f22~f24: 平面部分の主成分分析の固有値
9. f25~f27: 平面部分の主成分分析の固有値の比

4. 評価実験

4.1 認識結果の比較

曲面抽出を用いた特徴量の効果を調べるために、実験 1 では f1~f9 までを、実験 2 では点群全体の特徴量である f1~f24 すべての特徴量を Random forest 法に用いた。ただし、今回実験に用いる入力データは、セグメンテーションされた地物成分の中から、対象となる地物を手動で選択したものであり、6 個の対象地物以外は含んでいない。

表 1 では実験に用いる学習データと入力データの数、それぞれの実験での認識率(適合率と再現率)を示す。また図 2 に実験 2 での Random Forest 法において寄与度が高い特徴量の上位 10 個を示す。

Table.1 実験結果の比較

地物	学習	入力	実験 1 の認識率		実験 2 の認識率	
			適合率	再現率	適合率	再現率
電柱	100	101	94.0%	95.0%	97.0%	98.9%
ガードレール	44	44	100%	97.8%	100%	100%
街灯	86	73	80.8%	90.8%	95.8%	97.2%
標識	41	40	95.0%	82.6%	95.0%	88.3%
信号機	35	34	52.9%	69.2%	91.1%	91.1%
木	41	40	97.5%	78.0%	100%	100%




Fig.2 寄与度の高い特徴量

4.2 考察

表 2 の実験 1 と実験 2 の結果の比較を見ると、円柱と平面を分離した特徴量を加えることで、認識率が向上したことが分かる。このことから、セグメンテーションを利用した特徴量は地物の認識に有効であると言える。

ここで実験 2 での信号機と標識の認識率に着目する。ほかの地物の認識率と比較して、信号機は適合率が、標識は再現率が低い。すなわち信号機が標識として誤って分類されてしまうケースが多かった。原因として、標識と信号機は、形状的に相似であることが挙げられる。平面部分の抽出によりこの原因は解消されると考えていたが、図 3 のように、点の欠落などにより信号機の本体部分が平面抽出の対象となり、誤って分類されてしまったと考えられる。

また、街灯が誤って電柱として認識されるケースも存在した。今回、入力データとして選択した街灯の中には、少数ではあるが図 3(右)のように、電柱に街灯が付属した物も含んでいる。この街灯に対して円柱抽出を施すと、円柱部分として、電柱の部分が検出される。この円柱部分は、一般的な街灯の円柱部分と高さが大きく異なり、街灯よりも電柱の円柱部分の高さに近いと認識されてしまう。加えて、図 2 をみると、今回の分類では円柱部分の高さに対する寄与度が比較的高いことが分かる。これらの要因が重なったため、街灯内のいくつかが電柱として分類されてしまったと考えられる。




Fig.3 誤って分類された地物

5. まとめ

本研究では、前回の Random Forest 法を用いた地物の分類法に、地物から円柱と平面を抽出し、特徴量を計算する手法を提案した。それにより、全体的な認識率は向上した。

ただし、今回の手法では、入力データが分類対象とする 6 つの地物成分しか含んでいない。建物や壁、茂みなどについても学習させ、多様な地物データに対応できるようにする必要がある。また、今回は、近接した複数の地物が混在する場合は、例外として分類対象から除外した。こうした場合にも適切に点群を分離して、分類できるように手法を拡張していきたい。

参考文献

- 1) L.Breiman, "Random Forest", Machine Learning, Vol.45, pp.5-23, (2001)
- 2) J. He, H. Masuda Point-Clouds from Mobile Mapping System, ACDDE 2012
- 3) H.Masuda, S. Oguri, J. He: Shape Reconstruction of Poles and Plates from Vehicle-based Laser Scanning Data, Informational Symposium on Mobile Mapping Technology, 201