

点群と画像を用いた道路周辺地物の自動抽出

○森 悠真[†], 増田 宏[†]

[†]: 電気通信大学大学院情報理工学研究科 h.masuda@uec.ac.jp

概要: 移動計測装置(MMS)により取得される点群や画像には様々な地物が含まれているため, それらを種別ごとに自動で抽出することが求められる. しかし, 点群のみを用いた手法では, 類似した形状を誤認識することがある. また, 画像のみを用いた手法では, 見え方の違いや逆光などのために誤認識することがある. そこで本研究では, 点群と画像の両方を用いて, 地物の抽出と分類を行うことを考える. まず, 点群のセグメンテーションを行い, 地物の抽出を行う. 次に, 点群を画像上に投影することで, 地物に対応する画像を抽出する. 特徴量は, 画像と点群の両方から抽出し, それらを統合した特徴量ベクトルによって機械学習を適用する. 実測データを用いた評価実験では, 点群と画像の特徴量を組み合わせた提案手法により, 認識率が向上することを示した.

1. 緒言

道路周辺地物を効率的に維持管理するために, 車載の移動計測装置(Mobile Mapping System, MMS)が注目されている. MMSは, 図1に示すように, レーザスキャナ, デジタルカメラ, GPSなどを搭載し, 道路周辺の点群データやカメラ画像を取得することができる.

MMSで取得された点群や画像には様々な地物が含まれるため, 地物を種類ごとに分類する必要がある. しかし, 点群だけを用いた分類では, 形状の差異が小さい物体や, 形状が同じ標識などを正しく分類することは難しい. 一方, 画像による分類では, 逆光や撮影角度などの影響を受けやすいという問題がある.

本研究ではこうした問題を解決するためにMMSで取得される点群と画像の両方から抽出される特徴量を用いて地物の分類や抽出を行う手法について考える.

MMSでは, レーザスキャナとカメラが車両上に固定されているので, それらの相対位置から, 点群をカメラ画像上に投影できる. Wuら[1]は, 点群に対応する画像を抽出することで標識を分類する手法を示した. しかし, 分類には画像特徴量のみを用いているため, 色彩が似ている物体を誤認識していた.

本手法では, 点群から, 柱状物体やガードレールの候補点群を抽出し, それらに対応する画像を抽出する. 物体認識においては, 点群と画像の両方から特徴量を計算し, それらを融合した特徴量を用いて,

機械学習により分類を行う.

2. 柱状物体の抽出と分類

2.1. 概要

まず, 柱状物体の抽出と分類について考える. 点群からの柱状物体抽出には, 深野ら[2]の手法を用いる. この手法では, 点群の近傍点を接続してワイヤフレームモデルを作成した後, 一定間隔で水平に切断し, 切断点に対する円弧検出により柱状部を検出する.



図1. 移動計測装置(MMS)




図2 付属物点群の抽出



(a) 標識の点群 (b) 画像への投影 (c) 画像の抽出
図3 点群に対応する画像の抽出

柱状物体の分類では、柱状部に付属する物体が重要である。そこで、図 2 に示すように、柱状部の点群を取り除いた後、孤立した各ワイヤフレームモデルの点群を付属物として抽出する。検出された付属物点群はカメラ座標系に変換され、図 3 のように画像上に投影される。投影された点群をすべて含む矩形領域を画像から求め、その領域を付属物画像として抽出する。

次に、点群と画像から特徴量を抽出する。ここでは、3 次元の形状特徴量として、柱状部の半径と高さとテーパ、付属物の大きさや方向、柱状部と付属物の相対位置を用いた。変数の個数は 22 個である。

一方、画像特徴量は、Convolutional Neural Network (CNN) によって抽出された特徴ベクトルを用いた。ただし特徴ベクトルは 4096 次元で、3 次元特徴量と比較して大きいため、Random Forest (RF) 法による画像の分類器を作成し、寄与度の高い上位 64 個を用いた。

地物の分類は、RF 法を用いて、22 個の形状特徴量と 64 個の画像特徴量によって行う。

2.2. カメラ画像の選択

MMS には複数のカメラが搭載されており、走行しながら画像を撮影していく。これらのカメラ画像には、同一の付属物が複数回撮影されている。画像による物体認識の信頼性を高めるには、対象物が写っている画像群から、分類に適したカメラ画像を選択する必要がある。

MMS で計測されたカメラ画像と点群には、取得された時点の GPS 時刻が記録されている。したがって、その GPS 時刻を用いることで、点群とカメラ画像を同期させることができる。

本手法ではまず、抽出された付属物点群 $\{p_i\}$ の平均 GPS 時刻 $\bar{t}$ を算出する。図 4 に示すように、時刻 $\bar{t} \pm \Delta t$ で撮影されたカメラ画像に付属物点群 $\{p_i\}$ を投影し、投影された面積が最も大きい画像を付属物画像の抽出に用いる画像として選定する。

2.3. 点群から抽出される特徴量

道路周辺に存在する柱状物体は、付属物の形状や重量によって柱状部の形状が異なる。また、付属物の機能によってその付属物の設置位置が異なる。そのため本手法では付属物点群の特徴だけでなく、柱状部や両者の位置関係を表す特徴量を 3 次元特徴量として抽出する。本研究で用いた点群の特徴量を表 1 と図 5 に示す。

付属物点群からは、図 5(a) のような Bounding Box

を計算し、道路に平行な面の長辺の長さを a 、短辺の長さを b 、高さを c として取得する。また、3 次元空間上で主成分分析 (PCA) を行い、それぞれの固有値 $\lambda_1, \lambda_2, \lambda_3$ ($\lambda_1 \geq \lambda_2 \geq \lambda_3$) とその比 $r_1 = \lambda_1/\lambda_2$, $r_2 = \lambda_2/\lambda_3$, $r_3 = \lambda_3/\lambda_1$ 、道路面に対する第 1 主成





図 4 画像の選定



(a) 付属物 (b) 柱状部 (c) 相対的な位置関係

表 1 柱状物体の点群特徴

	特徴量の種類
付属物点群	Bounding Box の大きさ (a, b, c)
	PCA の固有値 ($\lambda_1, \lambda_2, \lambda_3$)
	PCA の固有値の比 (r_1, r_2, r_3)
	線状、面状、球状に分布する点の比率 (r_l, r_p, r_s)
	付属物の道路面に対する第一主成分方向 θ
	点群の平均反射強度 I
柱状部点群	長さ h
	テーパの割合 t
	底面と上面の円の半径 (D_1, D_2)
付属物と柱状部との関係	重心間距離 d_1
	最小距離 d_2
	付属物の柱状部底面からの距離 h_1
	付属物の柱状部上面からの距離 h_2

分方向との成す角 θ を計算する. さらに, PCA を計算することで得られる点群の形状特徴を用いる. 各点の近傍点の固有値の比 (r_1, r_2, r_3) がそれぞれ $r_1 \geq \alpha$ のときに線状, $r_1 < \alpha$ かつ $r_2 \geq \beta$ のときに面状, それ以外のときに球状と見なし, 全点に対するそれぞれの比率を (r_l, r_p, r_s) とする. また, 全点の平均反射強度 I を用いる.

柱状部からは, 図 5(b) に示すように, 底面と上面の円の半径 (D_1, D_2) , 長さ h , テーパの割合 t を特徴量として用いる.

最後に, 付属物と柱状部の関係として図 5(c) に示すように, 重心間距離 d_1 , 最小距離 d_2 , 付属物の柱状部底面・上面からの距離 (h_1, h_2) を求める.

2.4. 画像から抽出される特徴量

本手法では, Convolutional Neural Network (CNN) を用いて画像から抽出した特徴量を用いる. ここでは, ImageNet の訓練用画像データを用いて事前学習した AlexNet[3] の全結合層で得られた特徴量ベクトルを画像特徴量の候補とした.

CNN で抽出される特徴量は 4096 次元のベクトルであり, 3 次元特徴量の次元と比較して圧倒的に大きい. また, 多くが 0 の疎なベクトルである. そこで, Random Forest (RF) 法により付属物画像の分類器を作成し, 作成時に計算される寄与度を用いて画像特徴量の特徴選択を行う. ここでは, 分類を行うクラスの画像をそれぞれ約 500 枚ずつ用いて決定木を作成し, 決定木におけるジニ係数の減少量が大きいものを寄与度が高い特徴量とした. 本手法では, 寄与度が高い順に 64 個の特徴量を抽出し, 分類に用いる画像特徴とした.

表 2 柱状物体の付属物の分類結果

	案内 標識	歩行者 信号	信号機	街灯	標識	その他	F 値
点群のみ	96.6%	89.3%	93.9%	83.5%	91.4%	89.9%	90.6%
画像のみ	90.9%	92.9%	91.1%	81.2%	82.7%	93.1%	88.4%
提案手法	98.3%	92.9%	96.2%	90.5%	93.5%	93.5%	93.7%




図 6 特徴量の寄与度上位 10 個

2.5. 機械学習による分類

2.3, 2.4 で得られた画像と点群の特徴量を用いて柱状物体の付属物の分類を行う. 分類には RF 法を用いる. 評価実験では, 828 個の柱状物体を 2 分割し, 一方を学習データとした. また, 対象付属物を案内標識, 歩行者信号, 信号機, 街灯, 標識とし, いずれにも属さない柱状物体を「その他」クラスとした.

2.6. 分類結果

表 2 に分類結果を示す. 点群と画像の両方を用いることで, すべての地物で認識率が向上した. 特に, 「その他」として分類されるクラスにおいて分類精度が大きく上昇した. また, 図 6 に示すように, 寄与度上位 10 個には点群特徴量が 6 個, 画像特徴量が 4 個あり, 点群と画像の両方が分類に寄与したといえる.

3. ガードレールの抽出

3.1. 概要

ガードレールは, 板状のものやパイプ状のものなど形状の差異が大きく, 点群だけから抽出することは容易ではない. そこで, 点群と画像の両方を用いて, ガードレールを抽出することを考える.

まず, 図 7 に示すように, 点群から路面を除去し, 道路上の地物の点群を抽出する. 次に, 走行軌跡に垂直な平面により, 各地物の点群を小領域に分割する. ここでは, 50cm 間隔で分割を行った.

次に, 分割された点群を画像に投影し, 対応する画像を抽出する. 図 8 に, ガードレールを分割した点群と, 対応する画像を示す. これらの小領域の画像を用いて, CNN によりガードレールの画像を分類




図 7 候補点群の抽出




図 8 分割された地物と対応する画像

する. ここでは, 地物が複数の領域に分割されているので, 各地物ごとに得票率の高いものを分類結果とする.

ただし, ガードレールとして認識された点群には, ガードレール以外の点群も含むことがある. そこで, ガードレールと形状が大きく異なる点群を除外する. また, ガードレールとして認識された小領域が十分な長さで連結していない場合には, 誤認識として除外した.

3.2. 抽出された画像の分類+

抽出された画像を用いて地物の小領域の分類を行う. 分類対象はガードレールとし, それ以外の地物を「その他」クラスとした. 画像の分類には, ImageNet の訓練用画像データを用いて事前学習した VGG16[4] に, 抽出された画像のうち 686 枚のガードレールの画像と 905 枚のその他の地物の画像を用いて転移学習を行ったネットワークを用いた.


3.3. 抽出結果

表 3 に, 画像の分類結果を示す. また, 図 9 に分類の得票率によって改善した箇所を示す. 小領域の分類では一部に誤認識はあるものの, ガードレール全体としてはほとんどの小領域が正しく認識されており, 投票率による分類では, すべてのガードレールが認識できた.

また図 10 に, 分類結果をもとにガードレールとしてタグ付けされた点群を赤色で示す. 一部の小領域で過抽出があるものの, 大部分の点群が正しく認識できていることがわかる.


表 3 地物画像の分類結果

	ガードレール	その他	再現率	F 値
ガードレール	660	53	92.6%	0.951
その他	15	1548	99.0%	0.967
適合率	97.8%	96.7%		



(a) 不具合箇所 (b) 改善した点群

図 9 分類の得票率による改善



(a) 分類されたガードレールの点 (b) 拡大図

図 10 分類されたガードレール

4. 結言

本研究では, MMS で計測した点群と画像を用いて柱状物体とガードレールの抽出と認識を行った. 評価実験の結果, 点群と画像を組み合わせた物体認識は, 点群のみ, 画像のみによる物体認識に比べて認識率が向上した. また, 特徴量の寄与度の分析でも, 点群特徴量と画像特徴量は補完的であることがわかった.

今後は, 抽出対象の地物の種類を増加させ, 多様な地物の抽出を行なえるよう手法の改良を行っていく予定である. また, 様々な地域の計測データを用いた評価実験も行っていきたい.

参考文献

- [1] M. Soilán, B. Riveiro, J. Martínez-Sánchez, P. Arias: Traffic Sign Detection in MLS Acquired Point Clouds for Geometric and Image-Based Semantic Inventory, ISPRS Journal of Photogrammetry and Remote Sensing, 114 (2016) 92–101.
- [2] K. Fukano, H. Masuda: Detection and Classification of Pole-Like Objects from Mobile Mapping Data, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. I-3/ W5 (2015) 57-64.
- [3] A. Krizhevsky et al.: ImageNet Classification with Deep Convolutional Neural Networks, NIPS2012.
- [4] K. Simonyan, A. Zisserman: Very deep convolutional networks for large-scale image recognition, arXiv technical report (2016).

森悠真:2017 年, 電気通信大学情報理工学部知能機械工学科卒業. 同大学院情報理工学研究科修士課程在学中. 3次元計測, 点群処理, 物体認識に関する研究に従事.

増田宏:1985 年, 東京大学工学部精密機械工学科卒業. 1987 年, 同大学院工学系研究科修士課程修了. 同年, 日本アイ・ビー・エム(株)入社, 東京基礎研究所に勤務. 1998 年, 東京大学大学院工学系研究科 准教授, 2013 年より電気通信大学大学院情報理工学研究科 教授. 形状モデリング, 3次元計測, 点群処理, CAD に関する研究に従事. 工学博士.