

(14) 都市空間の点群データを用いた 深層学習による植生識別に関する基礎的研究

塚田 義典¹・梅原 喜政²・中原 匡哉³・窪田 諭⁴・
田中 成典⁵・川崎 悠史⁶

¹正会員 摂南大学准教授 経営学部 (〒572-8508 大阪府寝屋川市池田中町 17-8)
E-mail: yoshinori.tsukada@kjo.setsunan.ac.jp

²正会員 関西大学特別任命助教 先端科学技術推進機構 (〒564-8680 大阪府吹田市山手町 3-3-35)
E-mail: y.umeha@kansai-u.ac.jp

³正会員 大阪電気通信大学講師 総合情報学部 (〒575-0063 大阪府四条畷市清滝 1130-70)
E-mail: nakahara@oecu.jp

⁴正会員 関西大学教授 環境都市工学部 (〒564-8680 大阪府吹田市山手町 3-3-35)
E-mail: skubota@kansai-u.ac.jp

⁵正会員 関西大学教授 総合情報学部 (〒569-1095 大阪府高槻市霊仙寺町 2-1-1)
E-mail: tanaka@res.kutc.kansai-u.ac.jp

⁶非会員 関西大学大学院 総合情報学研究科 (〒569-1095 大阪府高槻市霊仙寺町 2-1-1)
E-mail: k923022@kansai-u.ac.jp

我が国では、建設生産プロセス全体の効率化および高度化を図ることを目的として、i-Construction を提唱し、点群データの活用を推進している。この背景の下、高精度かつ広域の点群データを計測できる車両搭載センシングユニットが注目されている。しかし、衛星電波の受信が困難な環境下では、点群データが生成できない課題や精度が低下する課題がある。既存研究では、RANSAC により植生以外の点を抽出し、SLAM により自己位置を補正して点群データを生成している。ただし、フレームによって空間特性が異なるため、平面の構成点数や繰り返し回数などの最適なパラメータが環境に応じて変化する課題がある。そこで、本研究では、深層学習を用いて、車両搭載センシングユニットで計測した点群データから植生を識別する手法を提案した。

Key Words: i-Construction, plant detection, vehicle mounted sensing unit, point cloud data, deep learning

1. はじめに

我が国では、高度経済成長期に施工されたインフラ構造物の老朽化が進み、効果的な点検、判定、補修・補強の方法¹⁾が求められている。そこで、国土交通省では、調査、設計、施工、検査、維持管理までの全てのプロセスにおいて ICT を活用する i-Construction²⁾を推進しており、3次元空間情報を最重要基盤と位置づけ、点群データの活用を推進している。特に、道路分野では、MMS (Mobile Mapping System)³⁾が導入され、道路空間の3次元情報を計測し、効率的に損傷箇所を発見する取り組みが検討されている。しかし、MMS は非常に高価なため、全国の諸官庁で導入することは困難である。

こうした背景の下、著者らは、市販の安価なセンサ機器を組み合わせた車両搭載センシングユニット⁴⁾を開発し、搭載機器のカタログスペックの範囲内で高密度な点群データを生成可能なことを確認した。ただし、高架下やトンネルなどの衛星電波の受信が困難な環境下では、自己位置の計測精度が低下するため、精緻な点群データを生成することができない。そのため、衛星の測位精度に依らず自己位置を推定する SLAM (Simultaneous Localization And Mapping)⁵⁾が注目されている。これは、連続する計測地点間において共通の地物に基づいて位置合わせすることで自己位置を算出し、周囲の点群データを生成する。しかし、車両のように移動速度が速い場合、連続する計測地点間で共通の特徴が減少する上、街路樹

や植栽（以下、植生）のような複雑な形状の地物が続くと、異なる地物同士を同一と推定し、誤った自己位置を算出する。この課題に対して、著者らは、RANSAC（RANdom SAmple Consensus）⁹⁾により植生以外の壁面や路面などの計測点を抽出し、それらの点のみを対象にSLAMを行う手法⁷⁾を提案し、一定の有効性を確認した。ただし、RANSACでは、フレームによって空間特性が異なるため、平面の構成点数や繰り返し回数などの最適なパラメータが環境に応じて変化する課題が見られた。

そこで、本研究では、SLAMによる自己位置の推定精度の向上を目指して、車両搭載センシングユニット⁴⁾で計測した点群データから深層学習により植生を識別する手法を提案する。

2. 事前実験

(1) 実験概要

深層学習を用いた点群データからの地物の識別手法として、ConvPoint⁹⁾が注目されている。ConvPointは、地上設置型レーザスキャナを用いて計測した都市空間の点群データセットであるSemantic 3D⁹⁾に対して、8種類の地物（路面、土壌、高い植生、低い植生、建物、人工物、移動体、車）を識別できることを実証している。

一方、本研究で対象とする車両搭載センシングユニット⁴⁾で取得する点群データ（図-1）は、1フレームごとに約2万点で構成されるため、地上設置型レーザスキャナで計測した高密度な点群データとは特性が異なる。本研究では、事前実験として、ConvPointとSemantic 3Dを用いて構築した地物識別モデルにより、車両搭載センシングユニットで計測した点群データから植生が識別できるかを確認する。

(2) 実験条件

本実験では、Semantic 3Dで公開されている15シーンの点群データを用いて地物識別モデル（図-2）を構築する。学習回数は、損失関数の値が0.01以下に収束した100回とした。評価データは、大阪府豊中市内の府道10号にて車両搭載センシングユニットで計測した点群データのうち、ランダムに選定した10フレーム分とする。点群データの構成点は、3次元座標と反射強度を保持する。車両搭載センシングユニットに搭載するレーザスキャナの計測精度は $\pm 0.03\text{m}$ 、計測間隔は約10Hzである。

精度評価では、地物識別モデルを用いて識別した結果と、手動で地物を識別した結果（以下、正解データ）とを比較する。そして、識別数に対する識別の成功数の割合から適合率、評価に用いるデータ数に対する識別の成功数の割合から再現率、適合率と再現率の調和平均から




図-1 車両搭載センシングユニットで計測した点群データ





図-2 地物識別モデルの構築

表-1 植生の識別精度

評価項目	10フレーム全体の平均
適合率	0.116
再現率	0.796
F値	0.198




図-3 地物の識別結果

F 値をそれぞれ算出する。

(3) 結果と考察

植生の識別精度を表-1、地物の識別結果を図-3 に示す。表-1を確認すると、10フレーム全体のF 値の平均が0.198 であることから、地物識別モデルの植生の識別精度が低いことがわかった。また、図-3 中において、低い植生を高い植生として誤識別する課題や建物を高い植生として誤識別する課題が見られた。これは、学習データが地上設置型レーザスキャナで計測した高密度の点群データに対し、評価データが車両搭載センシングユニットで計測した疎な点群データであったためと考えられる。そこで、新たなモデルの構築方法を検討する。

3. 植生識別アルゴリズム

本研究では、事前実験の結果より、車両搭載センシングユニットで計測した点群データに適用可能な植生識別モデルの構築方法を提案する。

(1) 学習データの生成

本研究では、車両搭載センシングユニットで計測した反射強度付きの点群データを学習データに使用する。学習データは、点群データ編集ソフトウェアを用いて手動で作成する。まず、道路空間上から任意の地物を選択する。識別対象の地物は、植生と植生以外の2 種類とする。次に、選択した各点に地物を示すラベルを付与して、地物ごとに識別した点群データを生成する。最後に、地物ごとに識別した点群データを学習データとする。

(2) 植生識別モデルの構築

本研究では、前述の手法で生成した点群データから事前実験と同様に ConvPoint を用いて、植生識別モデルを構築（図-4）する。植生識別モデルは、入力した点群データの中から、2 種類の地物（植生、植生以外）を識別し、各点に対して地物を示すクラスを付与するモデルである。

4. 実証実験

(1) 実験内容

本実験では、提案手法を用いて、車両搭載センシングユニットで計測した道路空間の点群データから植生を識別できるかを確認する。学習データに用いる点群データのフレーム数は、50 フレームとする。評価データは、学習データに含まれない 50 フレームとする。本実験で




図-4 植生識別モデルの構築

表-2 植生の識別精度

フレーム番号		5	15	73	93	全体平均
植生	適合率	0.992	0.767	0.952	0.993	0.945
	再現率	0.966	0.439	0.649	0.907	0.886
	F 値	0.979	0.558	0.772	0.948	0.908
植生以外	適合率	0.997	0.973	0.962	0.990	0.986
	再現率	0.999	0.994	0.996	0.999	0.995
	F 値	0.998	0.983	0.979	0.995	0.990
平均	適合率	0.994	0.870	0.957	0.991	0.965
	再現率	0.983	0.716	0.823	0.953	0.941
	F 値	0.988	0.771	0.875	0.971	0.949

【セルの背景色の凡例】

0.8～1.0 以下 0.6～0.8 以下 0.6 以下

は、評価データの 50 フレームの中から結果が特徴的な 4 フレーム（フレーム番号 5, 15, 73, 93）を抽出して評価する。学習回数は、損失関数の値が 0.01 以下に収束した 100 回とする。精度は事前実験と同様に評価する。

(2) 結果と考察

提案手法の植生の識別精度を表-2、識別結果を図-5 に示す。表-2を確認すると、全体での F 値の平均は 0.949 であることから、提案手法は事前実験で構築した地物識別モデルに比べて、高精度に植生を識別できることがわかった。加えて、植生の適合率の平均は 0.945、再現率の平均は 0.886 であることから、植生の点を植生以外の点と誤識別する確率は、植生以外の点を植生の点と誤識別する確率より高いことがわかった。図-5を確認すると、




図5 植生の識別結果

道路空間上に独立して存在する植生に対しては、高い確率で正しく識別できることが確認できた。しかし、フレーム番号 15, 73 に示すように、道路周辺の建物と隣接して存在する植生は誤識別する課題が見られた。これは、学習データの計測環境に偏りがあり、フレーム番号 15, 73 のような植生と建物が隣接する環境が少なかったためと考えられる。この課題に対しては、多様な計測環境を含む学習データを用いる方法や、反射強度のみならず、色情報を保持した点群データを利用する方法で改善できると考えられる。

以上より、深層学習を用いることで、車両搭載センシングユニットで計測した点群データから植生を高精度に識別可能になったことがわかった。植生が存在する場所によって精度に差が見られたため、今後は、多様な計測環境を含む学習データを用いることや、色付き点群データを使用することで提案手法の高精度化を図る。

5. おわりに

本研究では、深層学習を用いて、車両搭載センシングユニットで計測した点群データから植生を識別する手法を提案した。そして、実証実験の結果より、高精度に植生を識別できることがわかった。しかし、建物と隣接して存在する植生は誤識別する課題が見られた。

今後は、多様な計測環境を捉えた点群データを学習データに加えることや色付き点群データを利用して提案手法の高精度化を図る。加えて、識別した植生を除去した点群データから、SLAM を用いて車両搭載センシングユニットの自己位置を推定し、その結果を走行速度に着目して補正する手法の有用性を検証する。また、車両搭載センシングユニット以外の機器で計測した点群データについても提案手法への適用可能性を確認する。

謝辞：本研究の遂行にあたり、携帯型 3 次元センシング技術研究会（カイザーSLAM）の各氏から貴重なご意見を賜った。ここに記して感謝の意を表する。

参考文献

- 1) 国土交通省：インフラメンテナンス国民会議、<<http://www.mlit.go.jp/sogoseisaku/im/about/index.html>>, (入手 2021.4.1)。
- 2) 国土交通省：i-Construction 推進コンソーシアム、<https://www.mlit.go.jp/tec/i-construction/3d_wg/index.html>, (入手 2021.4.1)。
- 3) 国土交通省：車両搭載センシング技術を活用した道路基盤地図データの収集実験の開始について、<<https://www.mlit.go.jp/common/001157623.pdf>>, (入手 2021.4.1)。
- 4) 窪田諭, 塚田義典, 梅原喜政, 中原匡哉, 田中成典：車両搭載型センシングユニットの設計・製作と計測実験による評価, 土木学会論文集 F3 (土木情報学), Vol.77, No.2, pp.II-58-II-67, 2021.
- 5) Zhang, J. and Singh, S.: LOAM: Lidar Odometry and Mapping in Real-time, Robotics Science and Systems Conference, 2014.
- 6) Fischler, M. and Bolles, R.: Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography, *Communications of the ACM*, Vol.24, No.6, pp.381-395, 1981.
- 7) 塚田義典, 梅原喜政, 中原匡哉, 田中成典, 窪田諭, 川崎悠史：特徴点抽出による MMS の自己位置補正に関する研究, 情報処理学会全国大会講演論文集, Vol.83, No.4, pp.33-34, 2021.
- 8) Boulch, A.: ConvPoint: Continuous Convolutions for Point Cloud Processing, *Computers and Graphics*, Vol.88, pp.24-34, 2020.
- 9) Hackel, T., Savinov, N., Ladicky, L., Wegner, D., Schindler, K. and Pollefeys, M.: Semantic3D.net: A New Large-Scale Point Cloud Classification Benchmark, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol.IV-1-W1, pp.91-98, 2017.