

(52) 道路区画線を対象とした機械学習による 3次元点群データの自動抽出に関する研究

江守 央¹・齋藤 幹貴²・佐田 達典³・岡島 正哲⁴

¹正会員 日本大学准教授 理工学部交通システム工学科 (〒274-8501 千葉県船橋市習志野台 7-24-1)

E-mail: emori.hisashi@nihon-u.ac.jp

²非会員 ヤマト運輸株式会社 (〒104-8125 東京都中央区銀座 2-16-10)

E-mail: csmo15049@g.nihon-u.ac.jp

³正会員 日本大学教授 理工学部交通システム工学科 (〒274-8501 千葉県船橋市習志野台 7-24-1)

E-mail: sada.tatsunori@nihon-u.ac.jp

⁴非会員 日本大学学部生 理工学部交通システム工学科 (〒274-8501 千葉県船橋市習志野台 7-24-1)

E-mail: csma16027@g.nihon-u.ac.jp

本研究は、ダイナミックマップへの活用を目指して、道路を計測した3次元点群データから白線を抽出する手法の検討を行った。区画線や中央線、停止線などの特徴量を用いて機械学習により属性付与を行い、自動抽出を可能とするアルゴリズムを構築した。その結果、データ処理の範囲をMMSで取得された道路空間全体に拡大しても対象物を適切に抽出できることを確認した。

Keywords : 3D point clouds, road lines, automatic extraction, machine learning, random forest method

1. はじめに

国内の自動運転は、総務省が主導する技術開発を目的とした戦略的イノベーションプログラムの一環として開発が行われている¹⁾。搭載センサーを用いた周辺車両認識の技術に加え、ダイナミックマップ(高度な地図情報)を活用した自車位置推定を実現することで、より安全な運用を目指している²⁾。ダイナミックマップにはMMS(モービルマッピングシステム)で取得された3次元の点群データを処理した3次元道路地図が用いられるが、路線ごとの点群は数千万～数億点、データサイズは数GBに及ぶ大容量であり、今後のダイナミックマップ運用を前提とすれば処理の効率化、省力化が求められる。

一方、野田ら³⁾・今村ら⁴⁾は、3次元点群データのうちRGB値、反射強度値に適切な上下限の閾値を設定し、対象となる道路地物を抽出した。また小林ら⁵⁾は、RGB値から付属する色彩情報である色相、彩度、明度を算出し

た上で、その特徴から人工物(信号機、看板、ポールなど)の抽出を行った。しかし、いずれにおいても自動抽出のアルゴリズム構築を今後の課題としている。よって、本研究では道路上の白線(区画線や中央線、停止線など)を対象として、3次元点群データから特徴量をもとに、機械学習によって対象に属性付与、自動抽出するアルゴリズムの検討を目的とする。

2. 検証対象と範囲

MMSから得られたデータは計測車両が走行する車線上を基準に、空間全体にわたって点群データが取得される。取得されたデータすべてを検証の範囲とすることはデータサイズの大きさから非常に煩雑となる。よって抽出性能の評価の観点において意味を損なわない程度に範囲を限定する(図-1)。




図-1 対象範囲

3. 使用するデータの計測と特徴

(1) 街路計測

本研究で使用するデータは 2018 年 8 月に千葉県船橋市習志野台（北習志野駅周辺）の市街地にて計測された 3次元点群データである。使用したMMSは図-2に示す。道路区画線が塗布されている主要市道を対象に計測を行っている（図-3）。

(2) 使用するデータ属性

使用する点群データの俯瞰イメージ画像を図-4に示す。なお、電柱や植栽などもサンプルに含まれるが、視覚上、道路面のみ示している。データ属性は平面直角座標系のXY座標と標高を含む座標値、RGB値および反射強度値である。3次元点群データが含まれるLAS形式から、必要な属性のみを取り出し、処理を行えるようにテキスト形式に出力した。G地点を学習に用いて、その他



図-2 使用したMMS(Trimble MX9)



図-3 街路計測位置 (Google Map より作成)




図-4 全サンプルのイメージ (RiSCAN より作成)

の地点を評価用として位置付ける。点群データは、正解（区画線と認識してほしい部分）、不正解（それ以外）に手作業で分類し、教師データとして学習させる。これをもとに評価用データを予測し、正誤を照らし合わせることで精度を評価する。サンプルとして計 11 か所の点群データを用意した。図-4にサンプルのイメージを示す。なお、白線が引かれていたであろう部分も含めて正解としている。

4. ランダムフォレスト法と検証フロー

(1) ランダムフォレスト法

機械学習とはAI（人工知能）の一種で、コンピューターで膨大なデータを学習し、潜在的なパターンを見つけ出す方法である。予め正解（すなわち対象物）と不正解（それ以外）に分類した教師データを用意し、そのパターンを機械に学習させることによって判別を行う。

本研究では機械学習ライブラリの Scikit-Learn⁶⁾にて提供されているランダムフォレスト法⁷⁾を使用した。

ランダムフォレスト法とは、予測や回帰に使用される機械学習アルゴリズムで、精度の低い予測器を複数組み合わせることで個々の予測器よりも性能を向上させることができる。学習データからまったく独立に個々の予測器を生成すると仮定した場合、多くの予測器が同様な誤りをする確率が下がるため、判別結果を多数決等で決定すると、全体として誤り率が低下することで精度が向上する。

予測器の生成にはできるだけ独立、すなわち異なった振る舞いをする予測器を複数作る必要がある。ランダムフォレスト法では学習データからランダムに抽出したデータをもとに予測器を生成することで独立なデータ集合を作成することができる。さらに、取り出したデータを復元し、生成したい決定木の数だけデータのランダム抽出を試行する「バギング」と呼ばれる手法を用いること




図-5 バギングのイメージ⁷⁾

で、各々のデータ集合に対して独立な予測器を作成することができるというものである（図-5）。

(2) 検証フロー

本研究の提案手法による自動抽出処理および検証作業のフロー図を図-6に示す。大まかに、機械学習に用いる教師データの a) 作成, b) 学習・抽出処理, c) 比較対象の抽出処理の3段階に分けられる。

a) 教師データの作成

教師データは道路区画線とそれ以外の2クラスのラベルを付与するため、点群処理ソフト上で点群を手作業にて分類した。白線がタイヤ痕などで黒ずんでいるものや剥離している部分も周囲に残った白線を参考にして道路区画線として分類している。学習したデータは学習器にとって既知であるため、未知の地点を評価サンプルと位置付ける。これにより学習地点以外のデータに対する汎用性能を評価することができる。抽出結果は教師データと比較することで各評価値を算出できる。

b) 学習及び抽出処理

学習サンプルはランダムフォレスト法にて学習させ、学習した決定木が含まれる予測器本体を保存する。この学習済み予測器を用いて評価サンプルを判別させ、道路区画線と判断されたもののみを取り出すことにより対象を抽出することができる。なお、学習から判別、抽出まで自動で行うことができ、学習済み予測器を用いることでサンプルデータ以外にも3次元点群データの抽出処理を適用できる。




図-6 検証フロー

c) 対象となる既存手法

既存手法³⁾では、道路区画線のRGB値及び反射強度値の分布特性から適切な上下限値を設定する方法を行っている。この既存手法において最も抽出精度が高かったのはRGB値のうちG(green)値とB(blue)値の差が0~23の範囲の条件であった。本研究では、この条件を各評価サンプルに適用し、評価値を算出する。以下、評価値は、比較対象の既存手法の結果と比較する。

5. 評価手法

抽出精度は再現率、適合率、F値の3種類を用いて評価する。正誤は本検証における教師データのクラスと抽出結果のクラスを照らし合わせて判定する（表-1）。ここで道路区画線の点を1、その他の点を0と1点毎にラベル付けする。

再現率は抽出したい点群をどの程度抽出できたのかを示す。適合率は、閾値抽出した点群の中に、どの程度正しい点群が抽出できたのかを示す。F値は、再現率と適合率の調和平均を取った値であり、総合的な評価をすることができる。それぞれの式は式(1)~(3)に示す。単純な正答率も式(4)に示す。

$$\text{再現率} = \frac{TP}{TP + FN} \quad (1)$$

$$\text{適合率} = \frac{TP}{TP + FP} \quad (2)$$

$$F \text{ 値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}} \quad (3)$$

$$\text{正答率} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

6. 検証結果

図-7の上段に提案手法、下段に既存手法³⁾による抽出結果を示す。提案手法における地点Gは学習に用いており、参考として載せる。

表-1 正誤の判定

教師データ クラス	抽出結果 クラス	判定	意味
1	1	True Positive (TP)	正しく1
0	0	True Negative (TN)	正しく0
0	1	False Positive (FP)	誤って1
1	0	False Negative (FN)	誤って0




図-7 判別後の各評価値

提案手法の適合率は54.0～99.0%と誤る確率は少ない。F値は地点C、E～Kで72.6～93.8%と非常に高く、十分に抽出できている。一方、地点A・Bは30%に満たない。これは図-4の地点A・Bの白線の損傷が激しいことが原因と考えられる。同様に地点Dでも道路の一部が欠けているため、F値が52.2%と低いことから、再現率は白線の損傷具合に影響される。対して既存手法では、再現率が約55～90%と高い。しかし、適合率は最大でも10.4%と著しく低く、伴ってF値が最大18.6%と低い結果となった。

既存手法では、RGB値に一定の閾値を設けることで抽出を行っているが、各地点の結果の全てで提案手法が既存手法のF値を上回っており、既存手法に比べて機械学習による抽出が優れている結果となった。

7. おわりに

図-8に抽出イメージの一部として地点B、C、D、Eを示す。元データには正解をピンク色で示している。提案手法で最も精度の良い地点Eは車道外側線、中央線が明瞭に抽出できている。地点Bは中央線が若干読み取れる程度でほとんど抽出できていない。教師データに損傷した部分を含めても、提案手法では精度が向上することはなかった。また、地点Cの横断歩道が影に影響されて抽出されていない。既存手法では、範囲を道路空間に拡張した場合、ほぼ白線と判断してしまい再現率が非常に高く、一方で適合率が低いと考えられる。

今後は、白線が消えかかった部分を予測して抽出する方法を検討している。認識に用いられる機械学習法であるセマンティックセグメンテーションがあり、点群を2次元の特徴量画像に変換して学習することで、位置関係も認識することができると考えている。




図-8 抽出イメージ (RiSCAN より作成)

謝辞：実験にご協力いただいた株式会社ニコン・トリンブルの岩上弘明氏に心より謝意を表す。

参考文献

- 1) 国立研究開発法人新エネルギー・産業技術総合開発機構：戦略的イノベーション創造プログラム（SIP）自動走行システム／大規模実証実験，
<https://www.nedo.go.jp/activities/ZZJP_100125.html> (入手 2018.9.3).
- 2) 葛巻清吾：SIP 自動走行システム；ダイナミックマップ，戦略的イノベーション創造プログラム・システム基盤技術検討会，資料3-1，p.3，2016.
- 3) 野田圭宏，佐田達典，江守央：3次元道路地図の整備のための3次元点群データの処理に関する研究，日本大学理工学部学術講演会予稿集，pp.431-432，2017.
- 4) 今村一紀，佐田達典，江守央：MMSによる3次元点群データを用いた道路構造物抽出に関する研究，土木学会論文集F3，Vol. 71，No. 2，pp.106-113，2015.
- 5) 小林一郎，藤田陽一，杉原浩実，山本一浩：色彩情報による点群データの属性分析，土木学会論文集F3，Vol. 67，No. 2，pp. 95-102，2011.
- 6) Scikit learn：3.2.4.3.1. RandomForestClassifier，
<<https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>>，(入手 2018.9.3).
- 7) Powers D M W：Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation, Journal of Machine Learning Technologies, Volume 2, Issue 1, pp.37-63, 2011.
- 8) MathWorks:セマンティックセグメンテーションの基礎，ドキュメンテーション，
<<https://jp.mathworks.com/help/vision/ug/semantic-segmentation-basics.html>>，(入手 2018.9.3).