

Adaboost を用いた市街地レーザ計測点群のセマンティックセグメンテーション

北海道大学 ○峯俊秀, 伊達宏昭, 金井理

要旨

レーザ計測点群からオブジェクトごとにラベル付けされた点の固まりを抽出するセマンティックセグメンテーションは、市街地環境の3次元モデル化に必須である。本研究では、レーザ計測点群から superpoint, super-region と呼ばれる領域を抽出し、これら領域を用いて特徴量の抽出を行う。この特徴量を用いて機械学習手法の一つである Adaboost により学習を行い、オブジェクトごとの識別器を作成することで、市街地レーザ計測点群のセマンティックセグメンテーションを行う。

1. はじめに

近年、自動車にレーザ計測器を搭載し、道路面ならびに道路周辺物体の3次元形状情報を取得する MMS (Mobile Mapping System) が普及し、市街地環境を3次元点群で表現することが可能になっている。この点群を利用して市街地の3次元モデルを作成し、都市計画や防災等の各種シミュレーションに利用する試みがある。点群からの市街地3次元モデル化には、オブジェクトごとにラベル付けされた点の固まりを抽出するセマンティックセグメンテーション (図1) が必須であり、またこの結果に基づいて3次元モデル化が行われるため、高い識別精度が必要とされる。Golovinskiy[1]らは、機械学習手法である SVM (Support Vector Machine) を用いたセマンティックセグメンテーション手法を提案しているが、識別精度が低いといった問題がある。一方で、Lin ら [2] は機械学習手法である Adaboost[3]を用いた高精度なセマンティックセグメンテーション手法を提案している。しかし、Lin らの手法は住宅地環境を対象としており、この手法が複雑な市街地環境において有効であるかどうかは明らかではない。そこで本研究では、Adaboost を用いた、複雑な市街地から取得されたレーザ計測点群に適するセマンティックセグメンテーション手法を開発することを目的とする。MMS により取得された北海道大学周辺のレーザ計測点群に対する実験から、開発手法の識別精度の定量的な評価を行う。

2. 市街地点群のセマンティックセグメンテーション

2.1. セマンティックセグメンテーション手法の概要

本手法では、Lin らの手法をベースとしてセマンティックセグメンテーションを行う。また、Lin らの使用する特徴量に加え、複雑環境中の多種多様なオブジェクトの識別に有用な特徴量を Adaboost の学習に用いることで、市街地レーザ計測点群の高精度なセマンティックセグメンテーションを目指す。本手法の概要 (図2) を以下に示す。

- ① 学習用点群から superpoint (図3(a)) と呼ばれる領域を抽出し、この領域情報から特徴量を抽出する。
- ② superpoint の法線に基づいた領域成長法から super-region (図3(b)) と呼ばれる領域を抽出し、その形状特徴を superpoint の特徴量に付加する。
- ③ 得られた特徴量を用いて Adaboost で学習を行い、オブジェクトごとの識別器を作成する。
- ④ セグメンテーションを行う点群から同様の手順により特徴量を抽出し、作成した識別器により識別を行うことでセマンティックセグメンテーションを行う。

2.2. 点群からの特徴量抽出

2.2.1. 点群からの領域抽出

レーザ計測器から得られる点群の点数は膨大であり、点単位の学習、識別を行うと計算コストが非常に大きいとい




図1 セマンティックセグメンテーションのイメージ図

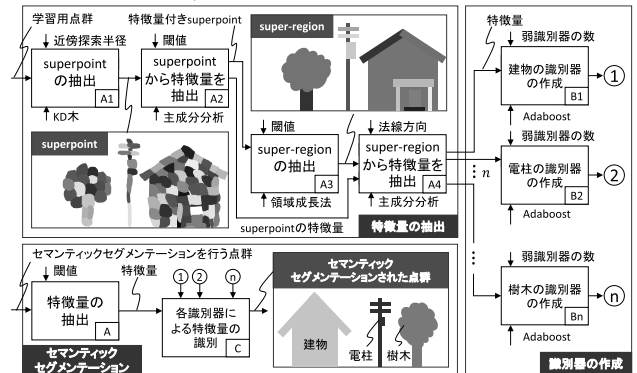


図2 セマンティックセグメンテーションの概要




図3 各領域の抽出例

う問題がある。そのため、点群から superpoint と呼ばれる領域を抽出し、この superpoint 単位で Adaboost による学習、識別を行うことで、計算コストを減少させる。また、高精度な識別には、より広い領域から抽出した形状特徴を用いることが有用である。そこで、superpoint をさらに拡張した領域である super-region から抽出した特徴量を superpoint に付加することで、識別に有用な特徴量を得る。

2.2.2. superpoint からの特徴量抽出

Adaboost で学習、識別に使用する特徴量を得るために、点群から superpoint と呼ばれる点の固まりを抽出する。superpoint の抽出は点群から無作為にシード点を選択し、近傍に存在する点を一つの領域とすることで行う。本手法では kd 木による近傍探索を用いてシード点の半径 0.15m 内に存在する点を抽出し、一つの領域とする。この処理をすべての点に対して行い、点群から複数の superpoint を抽出する。この superpoint から Lin らの手法では以下の特徴

量を抽出する。

- ① superpoint に含まれる点集合の重心のz (鉛直) 値
- ② superpoint の法線のz値：superpoint に含まれる点集合で主成分分析を行い、最小固有値に対応する固有ベクトルを superpoint の法線とする。
- ③ 近傍の superpoint の非平面性：注目する superpoint の近傍に存在する superpoint の非平面性の平均をとる。ここで、非平面性とは、superpoint に含まれる点集合の法線方向の厚さを表す。

本手法では、これらの特徴量に加えて、superpoint に含まれる点集合から主成分分析を行い、得られた固有値 $\lambda_1 \geq \lambda_2 \geq \lambda_3$ を用いて以下の3つの特徴量を抽出する。

- ④ 固有値の差 $\lambda_1 - \lambda_2$
- ⑤ 固有値の差 $\lambda_2 - \lambda_3$
- ⑥ 固有値 λ_3

superpoint の点の分布が、線状であれば④が、面状であれば⑤が、どちらでもなければ⑥が大きな値として抽出される。これら3つの特徴量は superpoint のスケールに依存するため、抽出後に総和が1になるように正規化を行う。

2.2.3. super-region からの特徴量抽出

superpoint から得られる特徴量は局所的であり、異なるクラスのオブジェクト上において同様の特徴量が抽出される場合がある。そこで、superpoint をさらに拡張した super-region と呼ばれる領域を抽出し、この領域の形状特徴を superpoint の特徴量に付加することで特徴量の差別化を行う。super-region の抽出は、無作為に選択した superpoint をシードとして、法線間角度に基づく領域成長法により行う。この super-region から Lin らの手法では以下の特徴量を抽出する。

- ① super-region の OBB (Oriented Bounding Box) の最大の面の面積
- ② super-region の OBB の体積
- ③ super-region の非平面性
- ④ super-region に含まれる superpoint の重心のz値の最大値と最小値の差

また本手法では superpoint と同様に、super-region に含まれる点集合の主成分分析を行い、得られた固有値を用いて以下の3つの特徴量を抽出する。

- ⑤ 固有値の差 $\lambda_1 - \lambda_2$
- ⑥ 固有値の差 $\lambda_2 - \lambda_3$
- ⑦ 固有値 λ_3


superpoint の特徴量抽出と同様に、これら3つの特徴量は総和が1になるように正規化を行う。

2.3. Adaboost によるオブジェクト識別機の作成

2.2 節の手順により抽出された特徴量を用いて Adaboost[3]により学習を行うことで、オブジェクトごとの識別器を作成する。Adaboost は機械学習手法の一つであり、正解データと不正解データを用意し、これらを分類する多数の弱識別器を求め、それらの重み付き多数決を行うことで高精度の識別を行う。また、学習中に学習サンプルの重みを適応的に更新することで、計算量の爆発と汎化性能の低下を抑制する。本手法では弱識別器の数を200として識別器を作成した。

3. MMS レーザ計測点群を用いた識別実験

上記の手順に基づいて Adaboost で建物の識別器を作成し、識別実験を行った。まず、50m×50mのグリッド状に分割されている北海道大学周辺の MMS レーザ計測点群の



(a)識別前の点群 (b)識別後の点群
図5 建物の識別結果

表1 点群Bのsuperpointの識別率

真クラス \ 識別クラス	建物	建物以外
建物	92.4%(93.5%)	7.6%(6.5%)
建物以外	2.5%(2.5%)	97.5%(97.5%)

うち、点群A (約21万点) を学習用の点群、点群B (約29万点) を識別実験用の点群として選択した。この点群Aから56533個のsuperpointが抽出され、建物のsuperpointに正解のラベル、それ以外のsuperpointに不正解のラベルを付加し、Adaboostで識別器を作成した。学習時間はCPU: XeonE5-2630 2.4GHz, RAM:32GBの環境下で約10時間であった。建物と識別された点を黒、それ以外を灰色で描画した結果を図5に示し、識別率を表1に示す。識別時間はCPU:Core i7 3.4GHz, RAM 16GBの環境下で32sであった。実験結果より、建物の点が抽出できていることが確認できる。しかし、電柱や街灯において誤検出が発生していることを確認した。これは、学習用の点群が少ないことが原因として考えられる。そのため、学習にさらに多くの点群を用いることで誤検出の改善が期待される。また本手法で追加した特徴量が識別に有用であるかどうかを確認するために、固有値に関する特徴量を用いず、同様の手順で識別を行った。表1中の括弧内の数値は、固有値に関する特徴量を用いなかった場合の識別率である。固有値に関する特徴量を用いることにより、建物superpointの識別率が1%減少しているが、その原因は、建物エッジ部分の誤識別であった。一方で、線状物体(電線等)の部分の誤識別が解消されるなど、他の物体の識別においては、固有値に関する特徴量は有用となる可能性が見られた。様々な物体のセマンティックセグメンテーションの実験とその有用性の確認は今後の課題とする。

4. おわりに

superpoint, super-region から抽出した特徴量を用いた Adaboost に基づくセマンティックセグメンテーション法を開発し、MMS 計測点群からの建物識別実験を行い、その有用性を確認した。また、樹木や電柱等の他のオブジェクトについても識別器を作成し、市街地レーザ計測点群全体のセマンティックセグメンテーションを行う。

参考文献

- [1] Aleksey Golovinskiy, et al., Shape-based recognition of 3D point clouds in urban environments, IEEE 12th International Conference, pp.2154-2161, (2009)
- [2] Hui Lin, et al., Semantic Decomposition and Reconstruction of Residential Scenes from LiDAR Data, ACM Transaction on Graphics (TOG) – Proc. of ACM SIGGRAPH 2013, 32, 4, 66, (2013)
- [3] Freund, Yoav, et al., A decision-theoretic generalization of on-line learning and an application to boosting, Journal of computer and system sciences, 55, 1, pp.119-139, (1997)