

市街地環境 MMS 計測点群のマルチスケール特徴抽出に関する研究

北海道大学

○加藤雅志, 伊達宏昭, 金井理

要 旨

近年, 車載型のレーザ計測器である MMS (Mobile Mapping System) の普及により, 道路や道路周辺のオブジェクトの三次元計測が可能となった. 本研究では, 点の抜けやノイズが多く点密度が一樣でないといった特徴を持つ市街地環境 MMS 計測点群から局所形状特徴量をロバストに推定するためのマルチスケール特徴抽出法, および点分類法を提案しその有効性を事例により示す.

1 はじめに

近年, 中・長距離レーザ計測器を用いた大規模環境計測技術は, 土木測量, 建築, 考古学, プラントなど様々な分野で利用されている. MMS(Mobile Mapping System)は, 車載型のレーザ計測器により道路やその周辺のオブジェクトの 3 次元計測が可能であり, 計測点群はモデリングや物体認識などに利用されている. モデリングや物体認識に点群を利用する際, 点の三次元座標に加えて, 法線や曲率といった局所的な形状の特徴量が必要とされる. しかしながら, MMS 計測点群は点の抜けやノイズが多く点密度が一樣でないため, ロバストな特徴抽出が困難である. そこで, 本研究は Pauly ら[1]の特徴抽出手法を元に市街地環境 MMS 点群から特徴量をロバストに推定するためのマルチスケール特徴抽出法, および点分類法を提案し, その有効性を示す.

2 マルチスケール特徴抽出法

2.1 概要

点群の主成分分析は, 法線や近似曲率の推定, 点分類などに有用であるが, 対象のスケールに応じた適切な処理範囲(近傍)を決定することが難しいことや, 抽出される特徴が点密度や点分布の違いの影響を受けやすいといった問題が存在する. それに対して, Pauly ら[1]はスケール空間における特徴抽出処理の点群への応用を行い, 異なる近傍における処理結果を融合した特徴量の推定法を提案した. この手法の特徴として, 対象形状のスケールに依存しにくいことや, 点分布の差やノイズにロバストであること, 特徴抽出の精度が高いことが挙げられる. しかしながら, Pauly らはこの手法を大規模点群には適用していない. そこで, 本研究ではこの手法の MMS 点群への適用を試みた.

このマルチスケール特徴抽出[1]に基づく特徴点の抽出手法の概要を図 1 に示す. MMS 計測点群を入力とし, 主成分分析を用いたマルチスケール特徴量 ω_i に基づく特徴点を抽出する. また, 周辺点の分布をもとに, マルチスケール特徴抽出では得られないサーフェス境界点の抽出を行う. 本研究では, マルチスケール特徴抽出により得られる特徴点と境界点とを点群の特徴点とする.

2.2 マルチスケール特徴に基づく特徴点抽出法

まず, マルチスケール特徴量の計算の元となるサーフェス変化量の計算法を述べる. 点 i を中心とする半径 r の球内に存在する点集合 i_r^* を用いた式(1)の分散共分散行列 C_i^r を求め, その固有値解析を行う.

$$C_i^r = \frac{1}{|i_r^*|} \sum_{j \in i_r^*} (\mathbf{p}_j - \bar{\mathbf{p}})^T (\mathbf{p}_j - \bar{\mathbf{p}}) \quad (1)$$

ここで, $\bar{\mathbf{p}}$ は i_r^* の重心であり, \mathbf{p}_j は点 j の座標値である. 得られた固有値 $\lambda_0 \geq \lambda_1 \geq \lambda_2$ に対してサーフェス変化量 σ_i^r を $\sigma_i^r = \lambda_0 / (\lambda_0 + \lambda_1 + \lambda_2)$ で求める. σ_i^r は, 平面に近い形状上の点では 0 に近く, エッジやコーナーなどの特徴を持つ形状上では値が大きくなる.

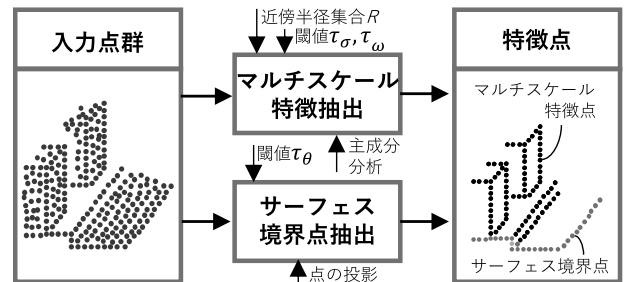


図 1 特徴点抽出手法概要




図 2 サーフェス境界点抽出

近傍半径集合 $R = \{r_j | j = 1, \dots, n, r_j < r_{j+1}\}$ に対して主成分分析を行い, 複数のサーフェス変化量を求める. そして, 与えられた閾値 τ_σ を超えるサーフェス変化量の数をマルチスケール特徴量 ω_i とする. 閾値 τ_ω 以上の ω_i を持つ点をマルチスケール特徴に基づく特徴点として抽出する.

2.3 サーフェス境界点の抽出法

2.2 節で述べたマルチスケール特徴量の計算では, サーフェスの境界点を特徴点として抽出することが出来ない. そこで, 点群に対して Linsen ら[2]の手法を用い, 境界点の抽出を行う. 本手法は, 境界上の点はその点の片側にしか点が存在しないという考えに基づいて境界点の抽出を行う. まず, 図 2(a)のように点 i の近傍点集合 i_r^* の最小二乗平面 f を求め, その平面に近傍点集合を投影する. 次に, 図 2(b)に示す, 点 i と隣り合う 2 点で定義される角度 $\theta_{j,j+1}$ を求める. $\theta_{j,j+1}$ が閾値 τ_θ を上回った場合は点 i をサーフェス境界点とする. 以上の計算を全点で実施することでサーフェス境界点を抽出する.

2.4 計算の効率化

マルチスケール特徴抽出を行う際, 全点で近傍半径集合 R に対して近傍点の抽出, 分散共分散行列 $C_i^{r_j}$ の算出を行うため, 非常に計算コストが高いという問題がある. そこで, 近傍探索を最大半径 r_n での一度にし, 行列は半径に応じて差分を更新することで冗長な計算を省き計算効率化を図る. 逐次的な $C_i^{r_j}$ の更新のためには, 点 i の r_j における近傍点集合 $i_{r_j}^*$ と $i_{r_{j+1}}^*$ における近傍点集合 $i_{r_{j+1}}^*$ の差分点群 $i_{r_{j+1}}^*$ を効率よく取得する必要がある. そこで, 図 3 のように最大半径 r_n の近傍点集合 $i_{r_n}^*$ から $r_m < \|\mathbf{p}_k - \mathbf{p}_i\| \leq r_{m+1} (m = 0, \dots, n - 1, r_0 = 0$ とする)となる近傍点 k を各半径に対して用意した点のリスト $d[m+1]$ に格納する.

式(1)で表される分散共分散行列 \mathbf{C}_i^r の成分 $c_{u,v}^r$ ($u, v = 1, 2, 3$)は式(2)に変形できる.

$$c_{u,v}^r = \frac{1}{|i_r^*|} \left(S_1^{i_r^*} - \frac{1}{|i_r^*|} S_2^{i_r^*} \right) \quad (2)$$

ここで, $S_1^{i_r^*} = \sum_{j \in i_r^*} a_{u,j} a_{v,j}$, $S_2^{i_r^*} = \sum_{j \in i_r^*} a_{u,j} \sum_{j \in i_r^*} a_{v,j}$ であり, $a_{i,k}$ は $i = 1$ のとき x_k , $i = 2$ のとき y_k , $i = 3$ のとき z_k である. 式(2)と求めた差分点群 i_r^* を用いると, 式(3)の通り, $\mathbf{C}_i^{r_{j+1}}$ の成分 $c_{u,v}^{r_{j+1}}$ は $\mathbf{C}_i^{r_j}$ の既知の成分に差分を加える事で求めることが可能となる.

$$c_{u,v}^{r_{j+1}} = \frac{1}{|i_{r_{j+1}}^*|} \left\{ S_1^{i_{r_{j+1}}^*} + S_1^{i_{r_j}^*} - \frac{1}{|i_{r_{j+1}}^*|} \left(S_2^{i_{r_j}^*} + S_2^{i_{r_{j+1}}^*} \right) \right\} \quad (3)$$

2.5 結果

図4にMMS計測点群に対してマルチスケール特徴抽出を行った結果を示す. ここでマルチスケール特徴抽出に用いたパラメータは, $R = \{0.25, 0.28, 0.30, 0.34, 0.37, 0.40\}$, $\tau_\sigma = 0.12$, $\tau_\omega = 3$ である. (b),(c)のシングルスケール特徴抽出では, 点密度の低い平坦部で特徴点が抽出される, またはエッジ部などの特徴形状部から特徴点が抽出されないといった問題が見られた. 一方, (d)のマルチスケール特徴抽出では, 点密度が高いところでも低いところでも特徴抽出を行うことが出来たが, 反面, 一部でエッジが抽出されていないといった問題も見られた. パラメータの調節により結果が変化するため, 適したパラメータの設定法に関して今後調査する必要がある. また, 2.4節で述べた計算の効率化の結果, 処理時間が806sから151sに短縮された.

3 点分類法

3.1 マルチスケールにおける点分類法

点の近傍点集合に対する主成分分析による固有値は, 各固有ベクトルに沿った点のばらつき(分散)を表す. したがって, 主成分分析の固有値を評価することで, 近傍点集合の分布状態を判定し, 周辺の形状のクラスを分類でき[3], 分類結果は様々な処理アプリケーションの前処理として有用である. 点分類は, 得られる固有値の差分特徴量 s_i を $s_1 = \lambda_0 - \lambda_1, s_2 = \lambda_1 - \lambda_2, s_3 = \lambda_2$ と定義し, $d = \arg \max_k s_k$ となる d で分類を行う. $d=1, 2, 3$ はそれぞれ, 線状分布, 平面状分布, 立体状分布を意味する. 図5に固有値の差分特徴量 s_i と分類される形状クラスを示す. この分類法は, データに対して適切な近傍を設定しなければ正しい結果が得られないという性質を持つ.

点分布の差や形状の複雑さ, そしてスケールの差にロバストな点分類を行うことを目的として, マルチスケール法に基づく以下の2つの点分類法を提案する.

方法1: マルチスケールで点分類を行い, 最も多く分類されたクラスを採用する.

方法2: マルチスケールで点分類を行い, 差分特徴量 s_1, s_2, s_3 を積分し, $c = \arg \max_k \sum_{r_i \in R} s_k(r_i)$ となる c で分類を行う.

3.2 結果

図6にマルチスケール点分類の結果を示す. ここで点分類に用いたパラメータは, (a), (b)のシングルスケール点分類ではそれぞれ $r = 0.20, r = 0.35$, 方法(1)と(2)のマルチスケール点分類では $R = \{0.20, 0.23, 0.26, 0.30, 0.32, 0.35\}$ とした. (a), (b)では, 半径を小さくすると点密度の低い道路面で平面状の点が線状の点であると誤認識される, あるいは, 半径を大きくすると点密度の高い階段が平面状の点である





図3 近傍点集合の格納例

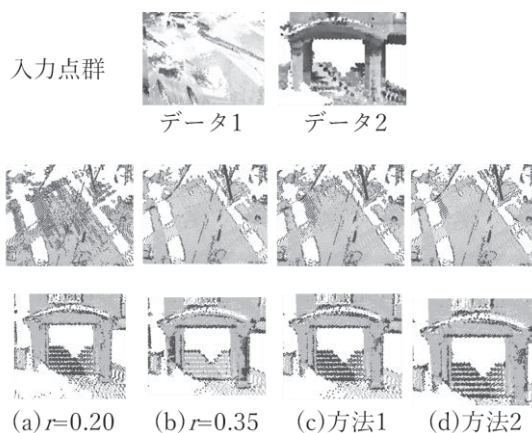


(a)入力点群 (b) $r=0.25$ (c) $r=0.40$ (d)MS特徴抽出

図4 マルチスケール特徴抽出結果

点分類クラス	線状	平面状	立体状
λ の大小関係	$\lambda_0 \gg \lambda_1 \cong \lambda_2$	$\lambda_0 \cong \lambda_1 \gg \lambda_2$	$\lambda_0 \cong \lambda_1 \cong \lambda_2$
固有値の差分 s	s_1 が最大	s_2 が最大	s_3 が最大

図5 固有値の差分特徴量 s_i と分類される形状クラス



(a) $r=0.20$ (b) $r=0.35$ (c)方法1 (d)方法2

図6 マルチスケール点分類結果

と誤認識されるといった問題が見られた. (c),(d)のマルチスケール点分類では, 点密度の低い道路面も点密度の高い階段も同時に誤認識の少ない点分類を行うことが出来た. (c)と(d)を比較すると, (c)では線状分布が多く見られ, (d)では平面状分布が多く見られた.

4 おわりに

本研究では, 主成分分析を用いたマルチスケール特徴に基づく特徴点抽出法と, マルチスケール点分類法の提案を行い, 実データへの適用を通してその有効性を確認した.

参考文献

- [1] Pauly, et al. Multi-scale Feature Extraction on Point-Sampled Surfaces. In Computer Graphics Forum, pp.281-289, 2001.
- [2] Linsen, L. Point Cloud Representation. In: Technical Report, Faculty of Computer Science, University of Karlsruhe, 2001.
- [3] Demantké, et al. Dimensionality Based Scale Selection in 3D Lidar Point Clouds, In: Proceedings of the ISPRS Workshop Laser Scanning, pp.97-102, 2011.