

主成分分析を用いたエッジの移動抑制による点群平滑化の改善手法

An Improved Method for Point Cloud Smoothing by Suppressing Edge Movement Using Principal Component Analysis

中山 光典[†] 杉山 秀治[†] 福田 大翔[†] 渡辺 裕[†]Kosuke NAKAYAMA[†] Hideharu SUGIYAMA[†] Hiroto FUKUTA[†] and Hiroshi WATANABE[†][†] 早稲田大学大学院 基幹理工学研究科 情報理工・情報通信専攻[†] GRADUATE SCHOOL OF FUNDAMENTAL SCIENCE AND ENGINEERING,
WASEDA UNIVERSITY

Abstract Point cloud denoising using deep learning is an effective method. However, this method confronts a problem of excessive smoothing of edges. In this study, we propose a new method to improve excessive smoothing by using principal component analysis to discriminate edges of point clouds and restricting their movement.

1. はじめに

現実空間を三次元認識する技術として、点群が活用されている。特に、点群が抱えるノイズの問題に対して、深層学習を用いた点群ノイズ除去は効果的な手法である。しかし、形状の角部分であるエッジが過剰に平滑化されてしまうという問題が起こる。

そこで本稿では、主成分分析を用いてエッジを判別し、補正ベクトルによる動きを制限することで、従来手法における過度な平滑化を改善する手法を提案する。

2. 関連研究

2.1. 点群特徴抽出

点群特徴抽出とは、点群データの法線や曲率等の基礎量を推定する手法である。特に、主成分分析[1]は共分散行列の固有値解析により行われる。ここで、本研究で使用する法線情報の算出方法を説明する。

まず、任意の点群における近傍集合を中心化するために、平均の位置へ移動させる。そして、移動後の点群を M とすると、共分散行列 C_i は式(1)で求められる。

$$C_i = M^T M \quad (1)$$

その後、 C_i の固有値分解により、固有値および固有ベクトルが得られる。固有値 Λ および対応する固有ベクトル E をそれぞれ式(2)、式(3)に示す。

$$\Lambda = \begin{pmatrix} \lambda_1 & & \\ & \lambda_2 & \\ & & \lambda_3 \end{pmatrix} \quad (2)$$

$$E = (e_1 \ e_2 \ e_3) \quad (3)$$

ここで得られる固有値のうち、最小の固有値に対応する e_3 が近傍集合の法線ベクトルとなる。

2.2. 深層学習を用いた点群ノイズ除去

深層学習を用いた点群ノイズ除去技術として、近傍探索によるグラフ畳み込みを用いた手法[2]が提案されている。Denoiser では、 k 点を含む点群 P を入力としたとき、各点に対するノイズ補正ベクトル d_i を出力する。その後、入力点群に加えてノイズ点を補正することで、滑らかな点群 $\tilde{P}$ が得られる。ノイズの補正は式(4)で表される。

$$\tilde{P} = \{p_i + d_i \mid 0 \leq i \leq k\} \quad (4)$$

しかし、形状の角部分であるエッジが、過剰に平滑化されてしまうという問題が残っている。

3. 提案手法

3.1. エッジ判定処理

任意の注目点 p_i における近傍集合 P_i に対して、主成分分析を用いて法線ベクトル n_i を算出する。このとき、注目点 p_i の座標を (x_0, y_0, z_0) とする。また、法線ベクトル n_i を式(5)で定義する。

$$n_i = (a \ b \ c) \quad (5)$$

算出した法線ベクトル n_i を用いて、近傍集合 P_i の平面近似を行う。平面方程式は、 P_i の重心 $(\bar{x}, \bar{y}, \bar{z})$ を通るため、式(6)で近似される。

$$a(x - \bar{x}) + b(y - \bar{y}) + c(z - \bar{z}) = 0 \quad (6)$$

また、平面方程式における係数 d は式(7)で表される。

$$d = -a\bar{x} - b\bar{y} - c\bar{z} \quad (7)$$

その後、注目点 p_i と平面方程式の距離 r に基づき、閾値 τ を用いてエッジと判定された点を集合 E に追加する。

表 1 従来手法および提案手法の各補正ベクトルに対するノイズ補正精度の評価

	従来手法	提案手法 (係数 l)								
		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
Chamfer-Distance (↓)	1.1511	1.1764	1.1614	1.1383	1.1316	1.1175	1.1206	1.1317	1.1378	1.1415

距離 r およびエッジ判定処理を, それぞれ式(8), 式(9)に示す.

$$r = \frac{|ax_0 + by_0 + cz_0 + d|}{\sqrt{a^2 + b^2 + c^2}} \quad (8)$$

$$\text{if } r \geq \tau : p_i \in E \quad (9)$$

3.2. 補正ベクトルの調整

エッジの過剰な平滑化に対し, 補正ベクトルの調整を行う. 具体的には, k 点を含む点群 P を入力としたとき, エッジと判定された点に対して Denoiser の補正ベクトル d_i に係数 l ($0 < l < 1$) を付け, 大きさの調整を行う. 補正ベクトルについて, 式(10)に示す.

$$\text{if } p_i \in E : \{p_i + ld_i \mid 0 \leq i \leq k\} \quad (10)$$

4. 実験

4.1. データセット

データセットには, 各形状 100000 点を持つ 28 種類の点群からなる PointCleanNet ノイズデータセットを使用する. 学習用データセットは, 学習用の 18 種類の形状において境界領域の対角線の 0.25%, 0.5%, 1.0%, 1.5%, 2.5% の標準偏差を持つガウスノイズを追加した点群から構成される. テスト用データセットは, テスト用の 10 種類の形状において境界領域の対角線の 0.5% の標準偏差を持つガウスノイズを追加した点群から構成される.

4.2. 実験パラメータおよび評価指標

本実験では, 近傍探索数を 16, エッジ判定処理の閾値 τ を形状の対角線の 7.5% の大きさとする. また, 補正ベクトル d_i の係数 l は, 0.1 から 0.9 まで 0.1 刻みで比較を行う. また, 評価指標には式(11)で表される Chamfer Distance[3]の平均値を使用する.

$$CD = \frac{1}{N} \sum_{\tilde{p}_i \in \mathbb{P}} \min_{p_j \in \mathbb{P}} \|\tilde{p}_i - p_j\|_2 + \frac{1}{M} \sum_{p_j \in \mathbb{P}} \min_{\tilde{p}_i \in \mathbb{P}} \|\tilde{p}_i - p_j\|_2 \quad (11)$$

Chamfer Distance は, 各ノイズ補正点 $\tilde{p}_i$ とその最も近い正解データ点 p_j との間の平均距離と, 各正解データ点 p_j とその最も近いノイズ処理点 $\tilde{p}_i$ との間の平均距離の合計である. ここで N, M は, ノイズ補正点 $\tilde{p}_i$ と正解データ点 p_j の点数である.




図 1 従来手法と提案手法のノイズ補正結果の比較

4.3. 実験結果

従来手法と提案手法によるノイズ補正精度の評価を行う. ここでは, 平面とエッジ部から構成される正二十面体の形状に対してノイズ除去を行った結果を図 1 に示す. また, データセット全体におけるノイズ除去精度の比較結果を表 1 に示す.

結果より, 係数 l の値が 0.5 の場合が最もノイズ補正精度が高くなり, それを境として精度の変化が現れている. そのため, 0.5 よりも小さくした場合はエッジ部分の点が本来の点よりも形状の外側に存在し, 大きくした場合は形状の内側に入り込むことが示唆される.

5. まとめ

本稿では, 点群のエッジ平滑化問題に対して, 主成分分析を用いた改善手法を提案した. 実験から, 提案手法がエッジ部分の平滑化問題に対して有効的であることが確認できた.

文 献

- [1] B.Jutzi, H.Gross, "NEAREST NEIGHBOR CLASSIFICATION ON LAZER POINT CLOUDS TO GAIN OBJECT STRUCTURES FROM BUILDINGS," International Archives of Photogrammetry and Remote Sensing, Band 38, Feb. 2009.
- [2] K.Nakayama, H.Fukuta, H.Watanabe, "Point Cloud Denoising and Outlier Detection with Local Geometric Structure by Dynamic Graph CNN," IEEE Global Conference on Consumer Electronics, OS-AIP, pp.156-159, Oct. 2023.
- [3] H. Fan, H. Su, L. Guibas, "A Point Set Generation Network for 3D Object Reconstruction from a Single Image," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.2463-2471, Jul. 2017.