

卒業論文概要書

Summary of Bachelor's Thesis

Date of submission: 01/31/2023 (MM/DD/YYYY)

学科名 Department	情報通信	氏名 Name	中山光典	指導 教員 Advisor	渡辺 裕 印
研究指導名 Research guidance	オーディオビジュアル 情報処理研究	学籍番号 Student ID number	1W19G701-3		
研究題目 Title	点群の局所幾何構造を考慮した外れ値検出およびノイズ除去に関する研究 Research on Outlier Detection and Noise Removal with Local Geometric Structure of Point Clouds				

1. まえがき

現実空間のデジタル化や機械の自動化を行うためには、点群が必要不可欠である。点群は写真測量やレーザセンサを用いて取得可能であるが、写真のマッチングミスや測定器の制限により、データには外れ値やノイズが混入している。そのため、データを直接扱うことは、処理精度の低下を招く。

従来のノイズ処理手法として PointCleanNet[1] があるが、パッチ内の局所幾何構造が考慮されていないため、ノイズ処理精度が低いという問題がある。そこで、本研究では DGCNN[2] をもとに、局所幾何構造を考慮したノイズ処理手法を提案する。提案手法では、各レイヤー毎に k-NN 探索[3] を用いて近傍点グラフを動的に構築し、点と同時に畳み込むことで局所幾何構造情報を持つエッジ特徴の生成を行う Res-GCN Block を導入する。エッジ特徴を用いて局所幾何構造を考慮することにより、点群ノイズ処理精度を改善できることを示す。

2. 従来手法とその問題点

PointCleanNet は、CNN を用いた点群ノイズ処理手法であり、外れ値検出を行う OutlierDetector とノイズ除去を行う Denoiser から構成される。OutlierDetector では、外れ値を持つ点群の局所パッチを入力として各点に対する外れ値推定確率を出力し、設定した閾値をもとに外れ値判定が行われる。Denoiser では、OutlierDetector を通して得られたノイズを持つ点群の局所パッチを入力として各点に対するノイズ補正ベクトルを出力する。その後、ノイズ点に加えてノイズ点の除去が行われる。

PointCleanNet の問題点は、パッチ内の局所幾何構造が考慮されていないことである。そのため、外れ値の検出精度が低いことや、曲面やエッジ部分が過剰に平滑化するという問題が存在する。

3. 提案手法

提案手法では、PointCleanNet のモデル構造に DGCNN をもとに構成した Res-GCN Block を導入する。提案手法のモデル構造を図 1 に示す。

提案モデルは、外れ値検出器の OutlierDetector とノイズ除去器の Denoiser から構成され、それぞれ Quaternion Spatial Transform, Res Block, Res-GCN Block から構成される。Res-GCN Block は、k-NN 探索および Res Block から構成されるグラフ畳み込みネットワークであり、点の関係性を表現するエッジ特徴を生成する。このエッジ特徴により、パッチ内の大域的な形状情報を維持したまま、局所幾何構造を反映した計算が行える。

Quaternion Spatial Transform は移動不変性の対処のために、四元数を用いてパッチの回転を行う。Res Block は勾配消失問題の対処のために、従来の CNN 構造にスキップ接続を導入したものである。

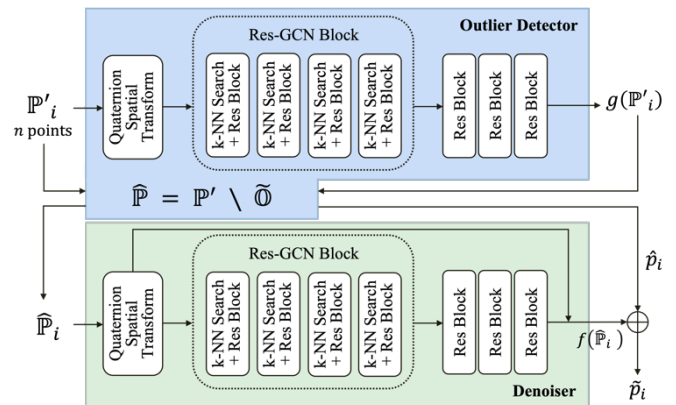


図 1 提案手法のモデル構造

4. 実験

4.1 外れ値検出器の学習および精度比較

外れ値検出器は、PointCleanNet 外れ値データセットを用いて学習を行った。損失には、推定された外れ値ラベル \tilde{o}_i と正解データ外れ値ラベル o_i

の L1 距離 L_o を用いた. 損失関数を式(1)に示す.

$$L_o(\tilde{p}_i, p_i) = \|\tilde{o}_i - o_i\|_1 \quad (1)$$

データセットの点群は, 外れ値と非外れ値の点数に偏りがあるため, 評価指標として AUPR の平均値を用いて外れ値検出精度の比較を行った. 従来手法と提案手法を用いて, 外れ値検出精度の比較を行った結果を表 1 に示す.

表 1 各外れ値の大きさにおける AUPR

Outlier Level	Conventional	Proposed
0%	0.947	0.978
0.5%	0.775	0.870
1.0%	0.665	0.781
2.5%	0.487	0.607

4.2 ノイズ除去器の学習および精度比較

ノイズ除去器は, PointCleanNet ノイズデータセットを用いて学習を行った. 損失には, ノイズ除去後の各点に対応する正解データの近傍内で最も近い点との L2 距離の二乗 L_s と最も遠い点との L2 距離の二乗 L_r を用いた. 損失関数を式(2)に示す.

$$L_\alpha(\tilde{p}_i, P_{\tilde{p}_i}) = \alpha L_s + (1 - \alpha)L_r \quad (\alpha = 0.99) \quad (2)$$

評価指標には, Chamfer Distance (CD)[4]の平均値を用いてノイズ除去精度の比較を行った. 従来手法と提案手法を用いて, ノイズ除去精度の比較を行った結果を表 2 に示す.

表 2 各ノイズの大きさにおける CD ($\times 10^{-2}$)

Noise Level	Conventional	Proposed
0.5%	1.28	1.21
1.0%	1.83	1.76
2.5%	8.18	8.12

4.3 評価実験

4.1 で述べた外れ値検出器および 4.2 で述べたノイズ除去器から構成される点群ノイズ除去モデルを用いて従来手法と提案手法の評価を行う. 評価実験では, 点群形状の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形状に対するノイズ除去精度を比較する. 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 2 に示す. また, ノイズ除去精度の比較結果を表 3 に示す.




図 2 正二十面体のノイズ処理結果

表 3 正二十面体のノイズ処理精度の比較

Method	Chamfer Distance ($\times 10^{-5}$)
Conventional	8.22
Proposed	7.26

図 2 より, 従来手法と比較して, 提案手法では平面のノイズが滑らかに除去されており, エッジ部の過剰な平滑化が抑制されたことが確認できる. また, 表 3 より, ノイズ処理精度を示す Chamfer Distance を低減できたことが確認できる.

5. 結論

本研究では, 従来の点群ノイズ処理手法である PointCleanNet に対し, DGCNN をもとに構成したグラフ畳み込みネットワーク Res-GCN Block を導入した新たな点群ノイズ処理手法を提案した. 提案手法では, 各レイヤー毎に近傍点グラフを動的に構築して点関係を明示的にすることで, 点群の局所幾何構造を考慮することが可能となった. 実験では, 外れ値検出精度とノイズ除去精度の評価を行うことにより, 提案手法の有効性を確かめた.

今後は, 低次元空間における k-NN 探索結果を伝搬させた場合や実際の取得点群に対する実験を行い, 提案手法の有効性を確かめる必要がある.

参考文献

- [1] M.J. Rakotosaona et al., "PointCleanNet: Learning to denoise and remove outliers from dense point clouds," In Computer Graphics Forum, vol.39, pp.185-203, Wiley Online Library, 2020.
- [2] Y. Wang et al., "Dynamic Graph CNN for Learning on Point Clouds," In Computer Graphics Forum, vol.39, pp.185-203, Wiley Online Library, Jun. 2019.
- [3] R.O. Duda, P.E. Hart, D.G. Stork, "Pattern Classification," New York: John Wiley, Section 4, Jan. 2001.
- [4] H. Fan et al., "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.

2022 年度 卒業論文

点群の局所幾何構造を考慮した
外れ値検出およびノイズ除去に関する研究

Research on Outlier Detection and Noise Removal
with Local Geometric Structure of Point Clouds

指導教員 渡辺 裕 教授

提出日：2023 年 1 月 31 日

早稲田大学 基幹理工学部 情報通信学科

1W19G701-3

中山 光典

目次

第1章	序論.....	3
1.1	研究背景	3
1.2	関連研究と問題点, および研究目的	3
1.3	本論文の構成	4
第2章	関連技術.....	5
2.1	まえがき	5
2.2	PointCleanNet	5
2.2.1	Outlier Detector	6
2.2.2	Denoiser	6
2.3	DGCNN	7
2.4	k-NN 探索	7
2.5	むすび	8
第3章	提案手法.....	9
3.1	まえがき	9
3.2	提案手法	9
3.3	むすび	11
第4章	実験・実験結果.....	12
4.1	まえがき	12
4.2	外れ値検出器の学習および精度比較	12
4.2.1	データセット	12
4.2.2	損失関数および学習パラメータ	12
4.2.3	AUPR による精度評価	12
4.3	ノイズ除去器の学習および精度比較	13
4.3.1	データセット	13
4.3.2	損失関数および学習パラメータ	13
4.3.3	Chamfer Distance による精度評価	13
4.4	評価実験	14
4.5	考察	15
4.6	むすび	16
第5章	結論と今後の課題.....	17
5.1	結論	17
5.2	今後の課題	17

謝辭.....	18
参考文献.....	19
図一覧.....	20
表一覧.....	21
研究業績.....	22

第1章 序論

1.1 研究背景

近年，社会的インフラ整備や製造業における生産現場をはじめ，様々な現場においてデジタル化が進められている．特に，データ処理技術とモデリング技術を用いて，現実空間上の物体や現象を仮想空間上に再現することはデジタルツイン[1]と呼ばれている．デジタルツインの実現により，現実空間と同条件の動作実験などが計算機上でシミュレーション出来るため，機器設計などでの開発効率性の向上やコスト削減が期待されている．また，自動運転車や自律型ロボットなどの自律型移動機器では，内蔵されたカメラやセンサから得られた情報を基に周囲のヒトや障害物などを検知し距離の測定を行う．計算機上での移動機器と外界の関係を計算機内で構築することで，安全に移動するルートを計算し，機器の自動化を実現している．

このような現実空間のデジタル化や機械の自動化を行うためには，点群データが必要不可欠である．点群データは三次元座標を持つ点で構成され，写真測量やレーザセンサを用いて取得可能である．しかし，点群データには写真のマッチングミスや測定器の制限による外れ値やノイズ[2]が含まれており，ノイズを持つデータを直接扱うことは物体検出やセグメンテーションなどの下流タスクにおける処理精度の低下を招く．そのため，コンピュータビジョンの分野において，点群ノイズ処理は重要な技術である．

1.2 関連研究と問題点，および研究目的

点群ノイズ処理は，他のデータから著しく異なる点を特定する「外れ値検出」とデータ内の不要なノイズ点を滑らかにする「ノイズ除去」からなる技術であり，フィルタベース，最適化ベース，深層学習ベースの3つの手法に分類される．まず，フィルタベースの手法としては，**Bilateral Filter**[3]が挙げられる．**Bilateral Filter**では，近傍点に対してフッティングさせた平面と各点の距離に基づいて重み付けを行い，その加重平均位置に点を移動させることでノイズ処理を行っている．そのため，エッジ部分の特徴は保てるものの平面や曲面が過剰に平滑化するという欠点がある．次に，最適化ベースの手法としては，移動最小二乗法[4]が挙げられる．移動最小二乗法では，近傍点にフッティングさせた曲面上に各点を投影することでノイズ処理を行っている．そのため，平面や曲面の特徴は保てるもののエッジ部分が過剰に平滑化するという欠点がある．最後に，深層学習ベースの手法としては **PointCleanNet**[5]が挙げられる．**PointCleanNet**は，深層学習ベースの手法であり，学習済みモデルと類似した形状や新たな形状に対して自動的にノイズ処理が行える．しかし，**PointCleanNet**では点群の重要な特性である局所幾何構造が考慮されておらず，外れ値の検出精度が低いことや，曲面やエッジ部分が過剰に平滑化するという問題が存在する．

そこで、本研究では各レイヤーの前で近傍点グラフを動的に構築して点関係を明示的にすることで、点群の局所幾何構造を考慮した新たな手法を提案する。実験により従来手法の外れ値検出精度の低さや、曲面やエッジ部分で過剰に平滑化が起こる問題点に対して、提案手法の有効性を示す。

1.3 本論文の構成

本論文の構成を以下に示す。

- 第1章 本章であり、本研究の背景、関連研究と問題点および研究目的について述べる。
- 第2章 本研究で用いる従来の点群ノイズ処理手法および関連技術について述べる。
- 第3章 本研究の提案手法について述べる。
- 第4章 本研究における実験の方法、結果および考察について述べる。
- 第5章 結論と今後の課題について述べる。

第 2 章 関連技術

2.1 まえがき

本章では、従来の点群ノイズ処理手法である PointCleanNet について述べる。また、関連技術であるグラフ畳み込みネットワーク DGCNN[6]および近傍探索手法 k-NN[7]について述べる。

2.2 PointCleanNet

PointCleanNet は、CNN を用いた点群ノイズ処理手法であり、図 2.1 に示すように、外れ値検出を行う Outlier Detector とノイズ除去を行う Denoiser から構成される。Outlier Detector では、外れ値を持つ点群 \mathbb{P}' の局所パッチ \mathbb{P}'_i を入力として各点に対する外れ値推定確率 $g(\mathbb{P}'_i)$ を出力し、設定した閾値をもとに外れ値判定が行われる。Denoiser では、Outlier Detector を通して得られた外れ値を取り除いた点群 $\hat{\mathbb{P}}$ の局所パッチ $\hat{\mathbb{P}}_i$ を入力として各点に対するノイズ補正ベクトル $f(\hat{\mathbb{P}}_i)$ を出力し、 $\hat{\mathbb{P}}$ に加えてノイズ点を補正することで、滑らかな点群 $\tilde{\mathbb{P}}$ が得られる。




図 2.1 PointCleanNet のモデル構造

PointCleanNet を構成する Outlier Detector および Denoiser の 2 つのネットワークは、それぞれ QSTN (Quaternion Spatial Transform Network), STN (Spatial Transform Network) [8], および FNN (Feedforward Neural Network) から構成される。

ここで、QSTN はパッチの回転を行うために四元数を用いて回転行列を出力するネットワークであり、STN はパッチの平行移動および回転を行うためにアフィン行列を出力するネットワークである。QSTN および STN は、点群の移動不変性に対して有効であり、外れ値に対してロバストになるように暗黙的に学習が行われる。また、FNN は

MLP で設計され、各点に対して別々に適用されるが、点群の順不変性のために各点間で重みは共有されている。

以下に、Outlier Detector および Denoiser の各ネットワークについて説明を行う。

2.2.1 Outlier Detector

Outlier Detector は、外れ値検出を行うネットワークである。Outlier Detector では、外れ値を持つ点群 \mathbb{P} の局所パッチ \mathbb{P}'_i を入力として、パッチ内の各点に対する外れ値推定確率 $g(\mathbb{P}'_i)$ を出力する。その後、設定した閾値をもとに式(2.1)で外れ値判定が行われ、外れ値として判定された点は外れ値集合 $\tilde{\mathbb{O}}$ に追加される。

$$\text{if } \tilde{o}_i > \text{threshold} : \tilde{o}_i \in \tilde{\mathbb{O}} \quad (2.1)$$

さらに、式(2.2)により外れ値を取り除いた点群 $\hat{\mathbb{P}}$ が得られる

$$\hat{\mathbb{P}} = \mathbb{P}' \setminus \tilde{\mathbb{O}} \quad (2.2)$$

損失関数には、推定された外れ値ラベル \tilde{o}_i と正解データ外れ値ラベル o_i の L1 距離 L_o を用いて学習を行う。Outlier Detector の損失関数を式(2.3)に示す。

$$L_o(\tilde{p}_i, p_i) = \|\tilde{o}_i - o_i\|_1 \quad (2.3)$$

2.2.2 Denoiser

Denoiser は、ノイズ除去を行うネットワークである。Denoiser では、Outlier Detector で外れ値を取り除いた後のノイズを持つ点群 $\hat{\mathbb{P}}$ の局所パッチ $\hat{\mathbb{P}}_i$ を入力として、各点に対するノイズ補正ベクトル $f(\hat{\mathbb{P}}_i)$ を出力する。そして、式(2.4)によりノイズ除去された滑らかな点群 $\tilde{\mathbb{P}}$ が得られる。

$$\tilde{\mathbb{P}} = \hat{\mathbb{P}} + f(\hat{\mathbb{P}}) \quad (2.4)$$

損失関数としては、ノイズ除去後の各点に対応する正解データ点を中心とした近傍内で最も距離が近い点との L2 距離の二乗 L_s と最も距離が遠い点との L2 距離の二乗 L_r を用いて学習を行う。 L_s は式(2.5)、 L_r は式(2.6)で表される。

$$L_s(\tilde{p}_i, \mathbb{P}_{\tilde{p}_i}) = \min_{p_j \in \mathbb{P}_{\tilde{p}_i}} \|\tilde{p}_i - p_j\|_2^2 \quad (2.5)$$

$$L_r(\tilde{p}_i, \mathbb{P}_{\tilde{p}_i}) = \max_{p_j \in \mathbb{P}_{\tilde{p}_i}} \|\tilde{p}_i - p_j\|_2^2 \quad (2.6)$$

Denoiser の損失関数を式(2.7)に示す。

$$L_\alpha(\tilde{p}_i, \mathbb{P}_{\tilde{p}_i}) = \alpha L_s + (1 - \alpha) L_r \quad (2.7)$$

ここで、QSTN により回転を行った点群は正準空間で定義されるため、ノイズ除去においては QSTN の出力の逆数をかけて世界空間に戻すための逆回転を行う必要があることに注意する。

2.3 DGCNN

DGCNN は、点群の分類とセグメンテーションを行う動的グラフ畳み込みネットワークである。分類タスクでは、点群を入力として各レイヤーの前で Edge Conv を行い、各レイヤーからの出力を結合して MLP を通すことで、分類スコアを出力する。セグメンテーションタスクでは、分類タスクと同様に群を入力として各レイヤーの前で Edge Conv を行い、各レイヤーからの出力を結合して MLP を通す。その後、カテゴリベクトルを合わせて MLP を通すことにより、セグメンテーションスコアを出力する。

ここで、Edge Conv では、注目点に対する近傍点を探索し、同時に畳み込むことで新たな点関係を表す特徴の生成を行う。この特徴を用いることで、従来の畳み込み手法では難しかった周囲の点の特徴を反映した計算が可能となる。DGCNN のモデル構造を図 2.2 に示す。

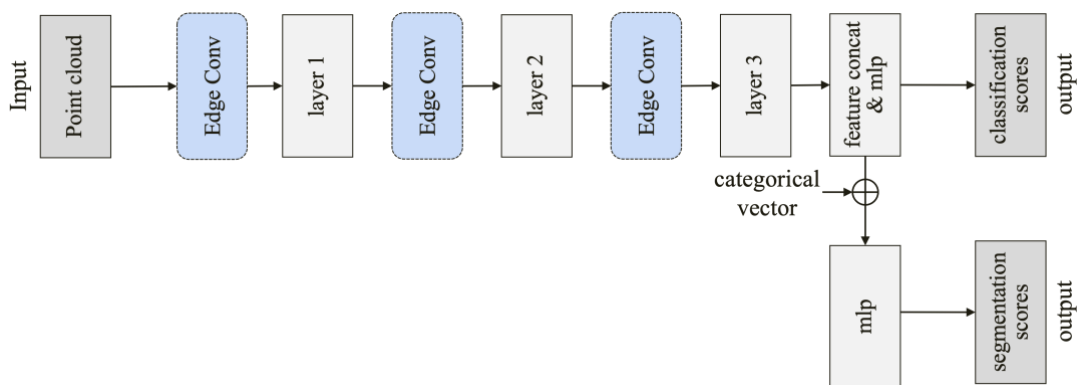


図 2.2 DGCNN のモデル構造

2.4 k-NN 探索

二次元グリッド上に規則的に定義される画像とは違い、点群は三次元グリッド上に不規則に定義されるため、注目点に対する近傍点を目視や手作業で特定することは非常に難しい。この時、近傍探索を用いて近傍点を特定することが可能となる。

代表的な近傍探索手法である k-NN 探索を図 2.3 示す。k-NN 探索では、中心点からの距離に基づいて近傍点 k 個（図 2.3 の例では 5 個）の探索を行う。

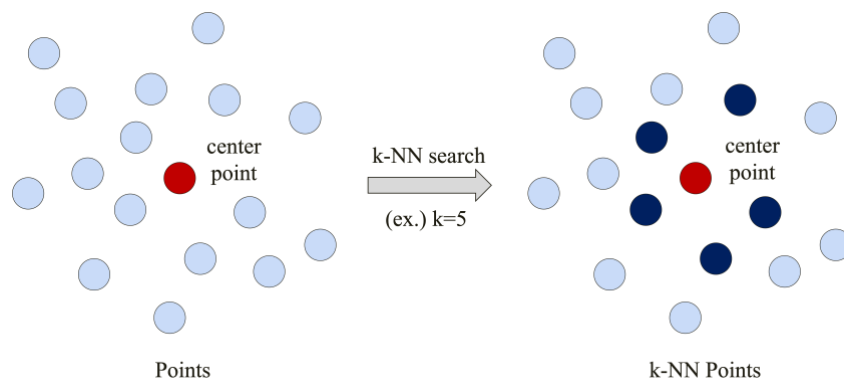


図 2.3 k-NN 探索

2.5 むすび

本章では，点群ノイズ処理の従来手法である PointCleanNet のモデル構造の説明および問題点について述べた．また，関連技術である DGCNN, k-NN について述べた．

第3章 提案手法

3.1 まえがき

本章では、PointCleanNet のモデル構造に、DGCNN をもとに構成したグラフ畳み込みネットワーク[9]である Res-GCN Block を導入した新たな点群ノイズ処理手法を提案する。提案手法では、各レイヤーの前で近傍点グラフを動的に構築して点関係を明示的にすることで、点群の局所幾何構造を考慮したノイズ処理が可能となる。

3.2 提案手法

従来の点群ノイズ処理手法である PointCleanNet では、点群をパッチに分割して入力しているが、パッチ内の局所幾何構造は考慮されていない。そのため、外れ値の検出精度が低いことや、曲面やエッジ部分が過剰に平滑化するという問題が存在する。そこで、DGCNN をもとに構成したグラフ畳み込みネットワークである Res-GCN Block を導入した新たな点群ノイズ処理手法を提案する。

提案手法のモデルは、点群ノイズ処理を行うグラフ畳み込みネットワークであり、従来手法と同様に外れ値検出を行う OutlierDetector とノイズ除去を行う Denoiser から構成される。各ネットワークは、Quaternion Spatial Transform Network, Res-GCN Block, Res Block から構成される。提案手法のモデル構造を図 3.1 に示す。また、Quaternion Spatial Transform Network を図 3.2, Res-GCN Block および Res Block を図 3.3 に示す。

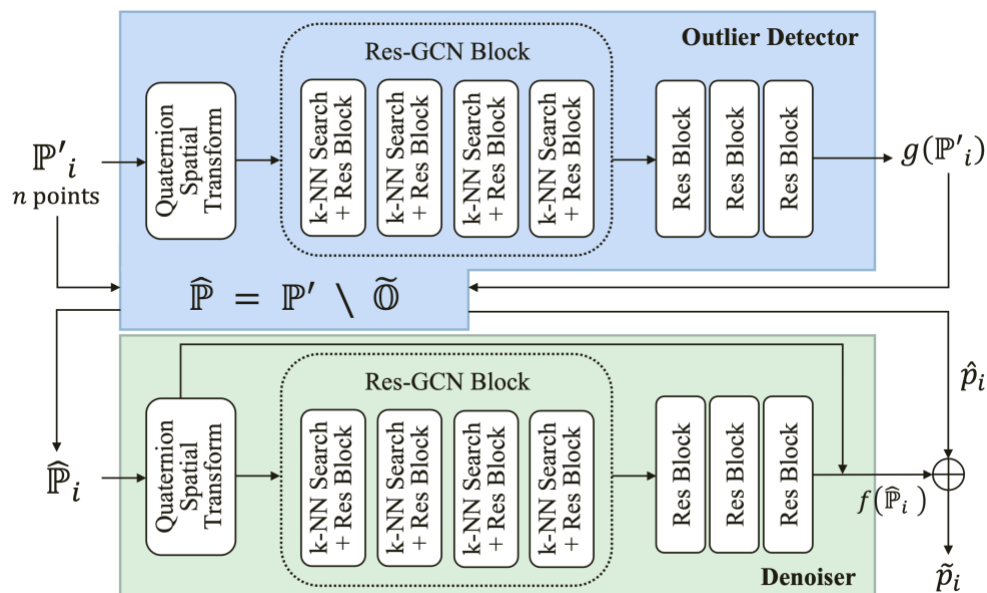


図 3.1 提案手法のモデル構造




図 3.2 Quaternion Spatial Transform Network

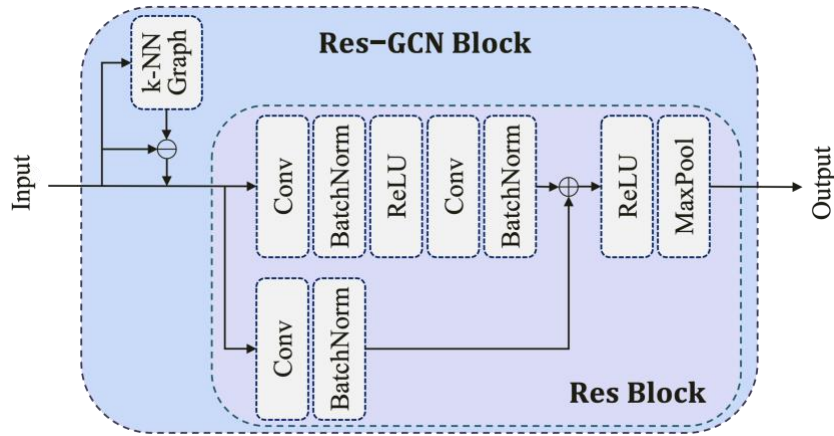


図 3.3 Res-GCN Block および Res Block

Res-GCN Block は、k-NN 探索および Res Block から構成されるグラフ畳み込みネットワークである。Res-GCN Block では、各レイヤーの前で各注目点 p_i に対する k-NN 探索により近傍点 p_j を探索する。そして、注目点 p_i から近傍点 p_j までの距離を計算することで、近傍点グラフ $p_j - p_i$ の構築を行う。その後、注目点 p_i と近傍点グラフ $p_j - p_i$ の両方を入力として畳み込むことで、点の関係性を表すエッジ特徴 x_e を生成し、Max Pooling でエッジ特徴の最大値 p_{ei} をとる。このエッジ特徴を用いることによりパッチ内の大域的な形状情報を維持したまま、局所幾何構造を反映した計算が行える。Res-GCN Block におけるエッジ特徴の生成フローを図 3.4 に示す。

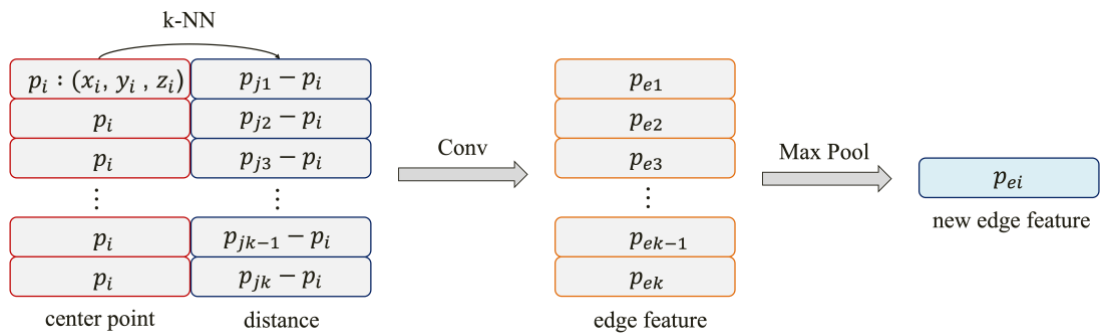


図 3.4 Res-GCN Block におけるエッジ特徴の生成フロー

また、従来手法と同様にパッチの回転を行うために四元数を用いて回転行列を出力する Quaternion Spatial Network を導入し、移動不変性への対処を行う。このとき、Res-GCN Block の導入により、従来手法における Spatial Transform が無くても安定的に学習を行えることが確認できたため、Spatial Transform は導入していない。Res Block は勾配消失の問題への対処のために、従来の CNN 構造にスキップ接続[10]を導入したものである。

3.3 むすび

本章では、本研究の提案手法である局所幾何構造を考慮した点群ノイズ処理手法について述べた。具体的には、PointCleanNet のモデル構造に、DGCNN をもとに構成したグラフ畳み込みネットワーク Res-GCN Block を導入する。Res-GCN Block において各レイヤーの前で近傍点グラフを動的に構築して点関係を明示的にすることで、点群の局所幾何構造を反映した計算を行うことが可能となる。

第4章 実験・実験結果

4.1 まえがき

本章では、本研究で用いたデータセット、実験方法、実験結果、考察について述べる。具体的には、まず本研究の点群ノイズ処理モデルにおける、外れ値検出器およびノイズ除去器の学習に用いたデータセット、実験方法、性能について述べる。その後、評価実験として、ガウスノイズを持つ2種類の点群をモデルに入力した時の従来手法と提案手法の実験結果の比較を行う。

4.2 外れ値検出器の学習および精度比較

4.2.1 データセット

データセットには、各形状 140000 点を持つ 28 種類の点群からなる PointCleanNet 外れ値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 20%の標準偏差を持つガウスノイズを追加して、10%から90%までの割合で外れ値に変換した点群から構成される。テスト用データセットは、ノイズなし、及び 0.5%, 1.0%, 2.5%のガウスノイズを持つテスト用の 10 種類の形状において境界領域の対角線の 20%の標準偏差を持つガウスノイズを追加して 30%の割合で外れ値に変換した点群、及び点群のサイズを 10%スケールアップさせた時の境界領域の中に外れ値を一様に分布させた点群から構成される。

4.2.2 損失関数および学習パラメータ

外れ値検出器は、式(2.3)の損失関数を用いて学習を行った。ここでは、従来手法と提案手法の外れ値検出器の精度比較を行う。このとき、閾値を 0.5 として、外れ値推定率が閾値よりも大きい場合に外れ値としての判別を行う。また、提案手法における k-NN の近傍探索数は 16 とする。学習における各パラメータは、バッチサイズ 32、ネットワークの重み初期値は He の初期化[11]、学習率 10^{-4} 、エポック数 800 である。

4.2.3 AUPR による精度評価

データセットの点群は、外れ値と非外れ値の点数に偏りがあるため、評価指標として AUPR の平均値を用いて外れ値検出精度の比較を行った。AUPR は、テスト結果の再現率-適合率の変化を曲線で表し、曲線下の面積の計算を行う。面積値は 0~1 の範囲をとり、値が大きいほど予測精度が高いことを示す評価指標である。

従来手法と提案手法を用いて外れ値検出精度の比較を行った結果を表 4.1 に示す。

表 4.1 各外れ値の大きさにおける AUPR 値

Outlier Level	Conventional Method	Proposed Method
0%	0.947	0.978 (+0.031)
0.5%	0.775	0.870 (+0.095)
1.0%	0.665	0.781 (+0.116)
2.5%	0.487	0.607 (+0.120)
Average	0.719	0.809 (+0.090)

4.3 ノイズ除去器の学習および精度比較

4.3.1 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%, 1.0%, 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.

4.3.2 損失関数および学習パラメータ

ノイズ除去器は, 式(2.7)の損失関数において $\alpha = 0.99$ として学習を行った. ここでは, 従来手法と提案手法のノイズ除去器の精度比較を行う. このとき, 提案手法における k-NN の近傍探索数は 16 とする. 学習における各パラメータは, バッチサイズ 32, ネットワークの重み初期値は $[-0.001, 0.001]$ の一様ランダム値, 学習率 10^{-8} , エポック数 800 である.

4.3.3 Chamfer Distance による精度評価

ノイズ除去器の精度の評価指標として, 式(4.1)で表される Chamfer Distance[12]の平均値を使用する.

$$\text{Chamfer Distance} = \frac{1}{N} \sum_{p_i \in \mathbb{P}} \min_{p_j \in \mathbb{P}} \| \tilde{p}_i - p_j \|_2^2 + \frac{1}{M} \sum_{p_j \in \mathbb{P}} \min_{p_i \in \mathbb{P}} \| \tilde{p}_i - p_j \|_2^2 \quad (4.1)$$

Chamfer Distance は, 各ノイズ処理点 \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, ノイズ処理点 \tilde{p}_i および正解データ点 p_j の点数である. Chamfer Distance により, 予測と正解データの両方から互いに評価することで点の一致度 (正解データ点群との類似度) を測定することができ, 値が低いほどノイズ除去精度が高いことを示す.

従来手法と提案手法のノイズ除去精度の比較結果を表 4.2 に示す.

表 4.2 各ノイズの大きさにおける Chamfer Distance ($\times 10^{-2}$)

Noise Level	Conventional Method	Proposed Method
0.5%	1.28	1.21 (-0.07)
1.0%	1.83	1.76 (-0.07)
2.5%	8.18	8.12 (-0.06)
Average	3.76	3.70 (-0.06)

4.4 評価実験

従来手法 (図 2.1) および提案手法 (図 3.1) において, ガウスノイズを持つ 2 種類の点群形状を入力としたときの, 点群ノイズ処理精度の評価実験を行う. 評価実験では, 形状の境界領域の対角線の 0.5% のガウスノイズを追加した 2 種類の形状を入力した場合の結果を比較する. ノイズ処理精度の評価指標には Chamfer Distance を使用する.

一つ目の点群は, 平面とエッジ部から構成される正二十面体の形状である. 正二十面体形状に従来手法と提案手法のノイズ処理を行った結果を図 4.1, ノイズ処理精度の比較を表 4.3 に示す.

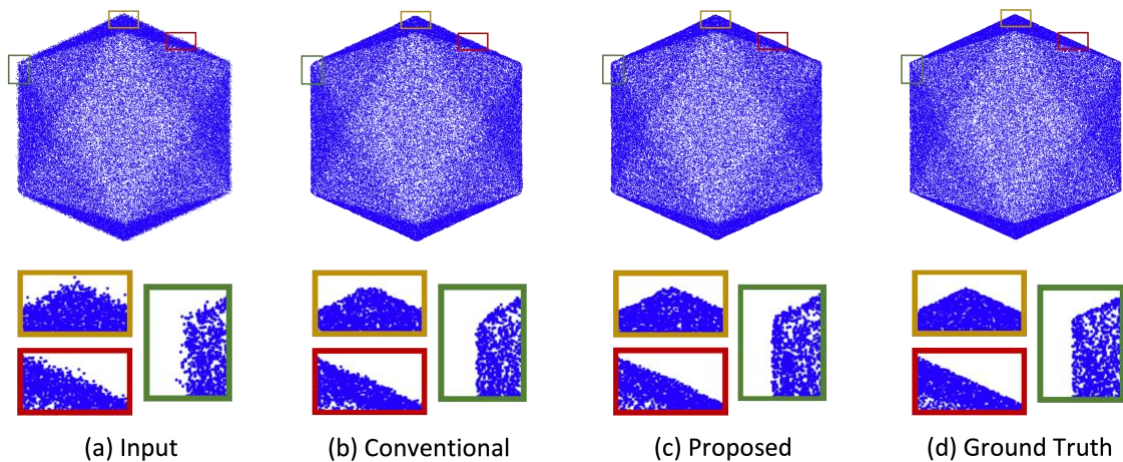


図 4.1 正二十面体のノイズ処理結果

表 4.3 正二十面体のノイズ処理精度の比較

Method	Chamfer Distance ($\times 10^{-5}$)
Conventional	8.22
Proposed	7.26 (-0.96)

二つ目の点群は、曲面とエッジ部からなる星型の形状である。星型形状に従来手法と提案手法のノイズ処理を行った結果を図 4.2，ノイズ処理精度の比較を表 4.4 に示す。

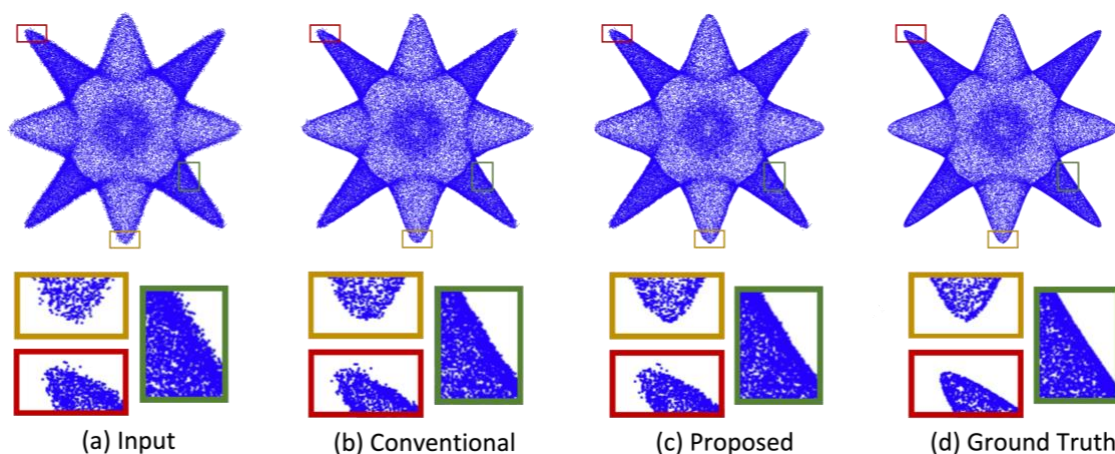


図 4.2 星型のノイズ処理結果

表 4.4 星型のノイズ処理精度の比較

Method	Chamfer Distance ($\times 10^{-4}$)
Conventional	1.28
Proposed	1.22 (-0.06)

4.5 考察

4.2 では、PointCleanNet 外れ値データセットを使用して外れ値検出器の性能評価を行った。表 4.1 より、提案手法では、各大きさの外れ値に対して平均で 0.090 の AUPR 向上が確認できる。特に、外れ値の大きさが 2.5% の場合には、0.120 の AUPR 向上を実現できた。

4.3 では、PointCleanNet ノイズデータセットを使用してノイズ除去器の性能評価を行った。表 4.1 より、提案手法では、各大きさのノイズに対して平均で 0.06×10^{-2} の Chamfer Distance の低減が確認できる。特に、ノイズの大きさが 0.5%, 1.0% の場合には、 0.07×10^{-2} の Chamfer Distance 低減を実現できた。

4.4 の評価実験では、正二十面体、星型の 2 種類の形状にガウスノイズを付与した点群を入力として実験を行った。正二十面体の形状にノイズ処理を行った結果は図 4.1 のようになった。従来手法では、直線の除去精度が悪い部分やエッジ部分の平滑化が見られるが、提案手法ではノイズ点を従来手法よりも綺麗に除去できており、エッジ部分を丸めることなく処理できていることがわかる。表 4.3 から、提案手法では、各大きさのノイズに対して平均で Chamfer Distance を 0.96×10^{-5} 低減できたことからノイズ処理精度が向上したことが確認できる。星型の形状にノイズ処理を行った結果は図 4.2 のようになった。従来手法では頂点付近の過剰な平滑化が見られるが、提案手法では頂点付近を過剰に丸めることなく処理できていることがわかる。表 4.4 から、提案手

法では, 各大きさのノイズに対して平均で Chamfer Distance を 0.06×10^{-4} 低減できたことからノイズ処理精度が向上したことが確認できる.

4.6 むすび

本章では, 本研究の点群ノイズ処理モデルにおける, 外れ値検出器およびノイズ除去器の学習に用いたデータセット, 実験方法, 性能について述べた. また, 評価実験として, ガウスノイズを持つ2種類の点群をモデルに入力した時の従来手法と提案手法の実験結果の比較を行った. 提案手法では, 外れ値検出器およびノイズ除去器のそれぞれで精度向上が達成でき, 評価実験でも有効性を示すことができた.

第5章 結論と今後の課題

5.1 結論

本研究では、従来の点群ノイズ処理手法である PointCleanNet に対し、DGCNN をもとに構成したグラフ畳み込みネットワーク Res-GCN Block を導入した新たな点群ノイズ処理手法を提案した。提案手法では、各レイヤーの前で近傍点グラフを動的に構築して点関係を明示的にすることで、点群の局所幾何構造を考慮することが可能となった。実験では、外れ値検出精度とノイズ除去精度の評価を行うことにより、提案手法の有効性を確かめた。具体的には、外れ値検出器およびノイズ除去器の精度比較を行った後、ガウスノイズを持つ2種類の点群形状を入力として点群ノイズ処理の評価実験を行った。結果として、外れ値検出器の精度を示す AUPR、ノイズ除去器の精度を示す Chamfer Distance を向上させることができた。また、評価実験からも2種類の点群形状に対する提案手法の有効性が示せた。したがって、提案手法により点群の局所幾何構造を反映した計算を行うことは、幾何学的な情報が重要となる点群ノイズ処理において有効であることが確認できた。

5.2 今後の課題

提案手法では、外れ値検出精度およびノイズ除去精度の向上が達成できた反面、高次元特徴空間における k-NN 探索により計算量を大幅に増加させるという問題が考えられる。そのため、今回は行えなかった計算量の比較を行う必要があると考える。さらに、低次元空間の k-NN 探索結果を各レイヤーの入力に伝搬させた場合や、近傍点グラフと点を別々に畳み込み加算した場合の精度、および計算量の比較を行いたい。また、本研究で用いたデータセットはコンピュータ上で仮想的に作成された点群であるため、実際の取得点群に対して実験を行い、提案手法の有効性を確認する必要がある。

謝辞

本論文の執筆に当たり、研究の方向性や問題点をご指導くださり、快適な研究環境を与えてくださった渡辺裕教授に感謝いたします。

毎週のゼミ活動において、研究の進捗や実験方法に関して丁寧なアドバイスをくださった早稲田大学情報通信研究センター招聘研究員の原潤一博士に感謝いたします。

また、コロナ禍により対面する機会が少ない中で、日頃から興味深い研究内容を共有していただき、温かく接してくださった渡辺研究室の皆様に感謝いたします。

最後に、私をここまで育ててくださり、常に心を支えてくださり、生活を支えてくださっている家族に感謝いたします。

参考文献

- [1] 国立研究開発法人科学技術振興機構 研究開発戦略センター, “デジタルツインに関する国内外の研究開発動向” 2021 年 9 月.
- [2] 土江庄一, “測定ノイズを許容した点群面張り,” *Unisys Tecnology Review*, vol.85, pp. 88-102, 2005 年 11 月.
- [3] J. Digne and C. Franchis, “The Bilateral Filter for Point Clouds,” *Image Processing On Line (IPOL)*, pp. 278-287, Jul. 2017.
- [4] M. Alexa, J Behr, D. Cohen-Or S. Fleishman, D. Levin, C.T. Silva, “Point Set Surfaces,” *VIS '01: Proceedings of the conference on Visualization '01*, pp. 21-28, Oct. 2001.
- [5] M.J. Rakotosaona, V.L. Barbera, P. Guerrero, N.J. Mitra, M. Ovsjanikov, “PointCleanNet: Learning to denoise and remove outliers from dense point clouds,” In *Computer Graphics Forum*, vol.39, pp.185-203, Wiley Online Library, 2020.
- [6] Y. Wang, Y. Sun, Z. Liu, S.E. Sarma, M.M. Bronstein, J.M. Solomon, “Dynamic Graph CNN for Learning on Point Clouds,” In *Computer Graphics Forum*, vol.39, pp.185-203. Wiley Online Library, Jun. 2019.
- [7] R.O. Duda, P.E. Hart, D.G.Stork, “Pattern Classification,” New York: John Wiley, Section 4, Jan. 2001.
- [8] C.R. Qi, H. Su, K.Mo, L.J. Guibas, “PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation,” *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.77-85, Jul. 2017.
- [9] T.N. Kipf, M. Welling, “Semi-Supervised Classification with Graph Convolutional Networks,” *2017 International Conference on Learning Representations (ICLR)*, Feb. 2017.
- [10] K. He, X. Zhang, S. Ren, J. Sun, “Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,” *2015 IEEE International Conference on Computer Vision (ICCV)*, pp.1026-1034, Dec. 2015.
- [11] K. He, X. Zhang, S. Ren, J. Sun, “Deep Residual Learning for Image Recognition”, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.770-778, Jun. 2016.
- [12] 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.

図一覧

図 2.1 PointCleanNet のモデル構造	5
図 2.2 DGCNN のモデル構造	7
図 2.3 k-NN 探索.....	7
図 3.1 提案手法のモデル構造.....	9
図 3.2 Quaternion Spatial Transform Network.....	10
図 3.3 Res-GCN Block および Res Block.....	10
図 3.4 Res-GCN Block におけるエッジ特徴の生成フロー	10
図 4.1 正二十面体のノイズ処理結果.....	14
図 4.2 星型のノイズ処理結果.....	15

表一覧

表 4.1	各外れ値の大きさにおける AUPR 値.....	13
表 4.2	各ノイズの大きさにおける Chamfer Distance ($\times 10^{-2}$).....	14
表 4.3	正二十面体のノイズ処理精度の比較.....	14
表 4.4	星型のノイズ処理精度の比較.....	15

研究業績

- [1] 中山光典, 原潤一, 渡辺裕 : “局所幾何構造を考慮した点群の外れ値検出 (Outlier Detection for Point Clouds with Local Geometric Structure)”, 2023 年 電子情報通信学会総合大会, Mar. 2023. (発表予定)