修士論文概要書

Master's Thesis Summary

Date of submission: 01/27/2025 (MM/DD/YYYY) 専攻名 (専門分野) 情報理工• 氏名 中山光典 Department 情報通信専攻 Name 指導 印 渡辺裕 教員 学籍番号 Seal オーディオビジュアル 研究指導名 CDAdvisor Student ID 情報処理研究 5123F093-0 Research guidance number 研究題目 局所空間の統計的解析に基づく点群ノイズ除去モデルの精度改善に関する研究 Title Research on Accuracy Improvement of Point Cloud Denoising Model Based on Statistical Analysis of Local Space

1. まえがき

デジタルインフラの実現や映像コンテンツの高度 化には、点群処理が必要不可欠である.点群はレー ザセンサや写真測量で取得可能であるが、測定器の 制限や写真のマッチングミスによりノイズが混入す る.データを直接扱うことは処理精度の低下を引き 起こす可能性があるため、点群ノイズ除去は重要な 技術となっている.

従来の点群ノイズ除去モデルには、ベクトル推定 やスコア推定を用いた手法が存在する.ベクトル推 定を用いたGraph-Based PointCleanNet[1]では、処 理時間の増加やエッジ部分の過剰な平滑化が課題で ある.また、スコア推定を用いたScore-Based Point Cloud Denoising[2]では、外れ値や密度を考慮せず モデルを学習していることが課題である。そこで本 研究では、従来の点群ノイズ除去モデルの問題点に 対して、グラフ畳み込みネットワークの最適化、主 成分分析を用いたエッジ移動の抑制、分散に基づく 近傍点数の動的化という三つの手法を提案する.

2. 関連研究

2.1. Graph-Based PointCleanNet

Graph-Based PointCleanNet は、グラフ畳み込み ネットワークを用いた点群ノイズ除去モデルである. 各レイヤーの前で注目点に対して近傍点グラフを構 築し、注目点と近傍点グラフ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量を生 成する.このエッジ特徴量により、パッチ内の大域 的な形状情報を維持したまま、局所部分の幾何学的 構造を反映した計算が可能である.

このモデルでは、膨大な処理時間がかかることに 加え、エッジ部分の過剰な平滑化が課題である.

2.2. Score-Based Point Cloud Denoising

Score-Based Point Cloud Denoising は, ノイズ除 去を目的として点群データのスコアを推定する手法 である. 点群の分布をモデル化し, 高確率領域への スコア推定を行うことで, 外れ値や低密度領域を含 む点群に対しても効果的なノイズ除去を実現する. しかし, 近傍点数を固定しているため, 外れ値や密 度の変動を十分に考慮できないという課題がある.

3. 提案手法

3.1. 効率的なグラフ畳み込み層の設計

提案手法では、性能を維持したまま計算コストを 削減することを目的に、Optimized-Graph CNN に 基づき低次元空間で構築した近傍点グラフを後続の レイヤーで共有するモデルを設計する.提案手法の グラフ畳み込み層を図1に示す.



3.2. 主成分分析を用いたエッジの移動抑制

エッジ部分の過剰な平滑化に対して,統計的手法 を用いた処理を適用する.まず,注目点における近 傍集合に主成分分析を施し,法線ベクトルを計算す る.法線ベクトルを用いて,近傍点の平面方程式を 近似し,注目点と平面の距離rを算出する.距離が 閾値 τ を超える場合,その点をエッジとして判定し, 集合Eに追加する.

最後に,式(1)に基づき補正ベクトル d_i に係数l(0 < l < 1)を付け,ベクトルの大きさを調整する.

$$p_i + ld_i (0 \le i \le k) : \text{ if } p_i \in E \tag{1}$$

3.3. 分散に基づく近傍点数の動的化

外れ値や密度の変動を考慮できていない問題に対 して、予備実験を基にノイズ点群の分散に応じて近 傍点数を動的に変化させてモデルを学習する.注目 点から遠い点の情報を省き、近傍点を制限すること で、特徴抽出とスコアの計算をより安定して行える ようになる.行列のサイズを近傍点数の最大値に合 わせて統一するため、点数が 32 に満たない場合には ゼロ埋め込みを行う.この操作は学習に影響を与え ず、計算効率を向上させる.処理内容を図2に示す.



図 2. モデル学習における近傍点数の動的化処理



図 3. 外れ値を含む Icosahedron データに対するノイズ除去精度の定性的評価

表 1. Icosahedron	データに対するモデルの評価	(↓)
------------------	---------------	-----

モデル	Chamfer-Distance	Time (s)
従来手法1	$1.56 imes 10^{-4}$	_
従来手法 2	$1.03 imes 10^{-4}$	$5.02 imes 10^{-4}$
提案手法	$1.04 imes 10^{-4}$	$4.35 imes 10^{-4}$

表2.係数1に伴うモデルの評価(結果一部省略) Chamfer-Distance ($\times 10^{-2}$) (\downarrow)

従 本毛津 9	提案手法				
征米于法 2	0.1	0.3	0.5	0.7	0.9
1.151	1.176	1.138	1.118	1.132	1.142

表 3. Kitten データに対するモデルの評価(↓)

モデル	Chamfer-Distance	Point-to-Surface
従来手法3	$3.12 imes 10^{-4}$	$1.01 imes 10^{-4}$
提案手法	3.07×10^{-4}	0.92×10^{-4}

実験 4.

レイヤー効率化による性能と処理時間への影響 4.1.

PointCleanNet(従来手法 1) 及び Graph-Based PointCleanNet(従来手法 2) に対する,提案手法 の性能比較を目的に評価する.

実験データには、PCNet データセットにおいて、 ガウスノイズ 20%を付与した後に標準偏差 1.5%よ り表面から離れた点の30%を外れ値として変換した Icosahedron データを用いる. 点群ノイズ除去精度 を Chamfer-Distance[3]と処理時間で評価した結果 を表1に示す.また,視覚的な評価結果を図3に示 す. 結果より, 提案手法では性能を維持したまま, 処理時間を削減できることを示した.

4.2. エッジの移動抑制による除去精度への効果

Graph-Based PointCleanNet(従来手法 2) に対 する,提案手法の性能比較を目的に評価する.実験 において, エッジ判定処理の閾値 τ は形状の対角線 の7.5%の大きさに設定した.また,提案手法の補正 ベクトルdiの係数lは,0.1から0.9までを0.1刻み で変化させて比較を行う.

実験データには、PCNet データセットを用いて Chamfer-Distance で評価した結果を表 2 に示す. 結果より,提案手法において係数1が0.5の場合に最 も良い性能を示すことが確認できた.









(a) 従来手法 3

(b) 提案手法

(c) 正解データ

図 4. ガウスノイズ 1.0%の Kitten データに対する ノイズ除去精度の定性的評価

4.3. 近傍点数の動的化による除去精度への効果

Score-Based Point Cloud Denoising (従来手法 3) に対する,提案手法の性能比較を目的に評価する. 実験データには, PUNet データセットにおけるガウ スノイズ 1.0%を付与した Kitten データを用いる. Chamfer-Distance と Point-to-Surface[4]で評価し た結果を表3に、視覚的な評価結果を図4に示す.

結果より、提案手法は各評価指標で良好な性能を 示した.加えて、視覚的にも優れた処理結果が得ら れることが確認できた.

5. むすび

本研究では、点群ノイズ除去モデルの精度改善を 目的として,新たに三つの手法を提案した.具体的 には、グラフ畳み込みネットワークの最適化、主成 分分析を用いたエッジ移動の抑制、分散に基づく近 傍点数の動的化を提案した.

各実験において従来手法に対する有効性を定量的 に示した.また,平面や曲面部分の処理についても、 視覚的に優れた結果が得られることを示した.

参考文献

- K. Nakayama et al., "Point Cloud Denoising and Outlier [1] Detection with Local Geometric Structure by Dynamic Graph CNN," 2023 IEEE Global Conference on Consumer Electronics, OS-AIP, pp.156-159, Oct. 2023.
- [2]S. Luo et al., "Score-Based Point Cloud Denoising," 2021 IEEE International Conference on Computer Vision, pp.4583-4592, Oct. 2021.
- H. Fan et al., "A Point Set Generation Network for 3D [3] Object Reconstruction from a Single Image," 2017 IEEE Conference on Computer Vision and Pattern Recognition, pp.2463-2471, Jul.2017.
- N. Ravi et al., "Accelerating 3D deep learning with [4]PyTorch3D, Dec. 2020.

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 修士論文

局所空間の統計的解析に基づく

点群ノイズ除去モデルの精度改善に関する研究

Research on Accuracy Improvement of Point Cloud Denoising Model Based on Statistical Analysis of Local Space

中山光典 (5123F093-0)

提出日:2025年1月27日

指導教員:渡辺裕教授

研究指導名:オーディオビジュアル情報処理研究

目 次

第1章		4
1.1	研究背景	4
1.2	関連研究と問題点....................................	4
1.3	本論文の構成	5
第2章	関連研究	6
2.1	まえがき....................................	6
2.2	PointCleanNet	6
	2.2.1 Outlier Detector	7
	2.2.2 Denoiser	7
2.3	Graph-Based PointCleanNet	8
2.4	Score-Based Point Cloud Denoising	8
	2.4.1 Feature Extraction	9
	2.4.2 Score Network	9
2.5	Dynamic Graph CNN	9
2.6	Optimized Graph CNN	10
2.7	PointPillars	10
2.8	むすび	11
第3章	ベクトル推定による点群ノイズ除去	12
第 3章 3.1	ベクトル推定による点群ノイズ除去 まえがき....................................	12 12
第 3章 3.1 3.2	ベクトル推定による点群ノイズ除去 まえがき....................................	12 12 12
第 3章 3.1 3.2	ベクトル推定による点群ノイズ除去 まえがき 提案手法	12 12 12 12
第 3章 3.1 3.2	ベクトル推定による点群ノイズ除去 まえがき 提案手法	 12 12 12 12 13
第3章 3.1 3.2 3.3	ベクトル推定による点群ノイズ除去 まえがき 提案手法	 12 12 12 12 13 14
第3章 3.1 3.2 3.3	ベクトル推定による点群ノイズ除去 まえがき	 12 12 12 12 13 14 14
第3章 3.1 3.2 3.3	ベクトル推定による点群ノイズ除去 まえがき 提案手法	 12 12 12 13 14 14 14
第3章 3.1 3.2 3.3 3.3	ベクトル推定による点群ノイズ除去まえがき提案手法3.2.1 効率的なグラフ畳み込み層の設計手法3.2.2 主成分分析を用いたエッジの移動抑制実験条件3.3.1 データセット3.3.2 評価指標評価実験	 12 12 12 13 14 14 14 15
第3章 3.1 3.2 3.3 3.4	ベクトル推定による点群ノイズ除去 まえがき	 12 12 12 13 14 14 14 15 15
第3章 3.1 3.2 3.3 3.4	ベクトル推定による点群ノイズ除去 まえがき	 12 12 12 13 14 14 14 15 15 16
第3章 3.1 3.2 3.3 3.4	ベクトル推定による点群ノイズ除去 まえがき	 12 12 12 13 14 14 14 15 16 17
第3章 3.1 3.2 3.3 3.4 3.5	ベクトル推定による点群ノイズ除去 まえがき 提案手法 3.2.1 効率的なグラフ畳み込み層の設計手法 3.2.2 主成分分析を用いたエッジの移動抑制 実験条件 3.3.1 データセット 3.3.2 評価指標 3.3.2 評価指標 3.4.1 グラフ畳み込み層の最適化によるモデル性能と処理時間への影響 3.4.2 エッジの移動抑制によるノイズ除去精度への効果 3.4.3 考察	 12 12 12 13 14 14 14 15 16 17 18
第3章 3.1 3.2 3.3 3.4 3.4 第4章	ベクトル推定による点群ノイズ除去 まえがき	 12 12 12 13 14 14 14 15 16 17 18 19
第3章 3.1 3.2 3.3 3.4 3.4 第4章 4.1	ベクトル推定による点群ノイズ除去 まえがき	 12 12 12 13 14 14 14 15 16 17 18 19 19
第3章 3.1 3.2 3.3 3.4 3.4 第4章 4.1 4.2	ベクトル推定による点群ノイズ除去 まえがき	 12 12 12 13 14 14 14 15 16 17 18 19 19 19 19
第3章 3.1 3.2 3.3 3.4 3.4 3.5 第4章 4.1 4.2 4.3	ベクトル推定による点群ノイズ除去 まえがき 提案手法 3.2.1 効率的なグラフ畳み込み層の設計手法 3.2.2 主成分分析を用いたエッジの移動抑制 実験条件 3.3.1 データセット 3.3.2 評価指標 評価実験 3.4.1 グラフ畳み込み層の最適化によるモデル性能と処理時間への影響 3.4.2 エッジの移動抑制によるノイズ除去精度への効果 さすび スコア推定による点群ノイズ除去 まえがき 予備実験 提案手法	 12 12 12 13 14 14 14 15 16 17 18 19 19 20

4.4	実験条件	20
	4.4.1 データセット	20
	4.4.2 評価指標	20
4.5	評価実験	21
	4.5.1 近傍点数の動的化によるノイズ除去精度への効果	21
	4.5.2 考察	23
4.6	むすび	23
第5章	結論	24
5.1	結論	24
5.2	今後の課題	24
謝辞		25
参考文南	ς	26
表一覧		28
図一覧		29
研究業績		30

第1章 序論

1.1 研究背景

近年,防災対策や都市計画の高度化に向け,デジタル技術を用いた社会インフラの構築が進め られている.特に,自動運転車のベクターマップでは,道路や周囲環境の形状を持っている点群 地図と走行中に取得したスキャンデータを重ね合わせることで,車両の位置や向きを推定してい る [1].また,映像分野においてもボリュメトリックキャプチャ[2]と呼ばれるコンテンツを三次元 化する技術が注目されている.複数台のカメラで被写体を取り囲むように配置し,撮影データを 統合することで,被写体の三次元形状や色の推定を行う.この技術により,被写体をメッシュや 点群のような三次元形式のデータとして表現することが可能となり,仮想視点の映像を生成でき る.さらに,Epics Game 社は, MetaHuman Technology [3]と呼ばれるデジタルヒューマン作成 フレームワークの提供を開始している.スマートフォンで顔の特徴を三次元計測しデータを読み 込むことで,忠実度の高いアバターの作成が可能となっている.

このように、デジタルインフラの実現や映像コンテンツの高度化を進めるために、点群を扱う 処理が必要となる.しかし、点群には地図データのマッチングミスやレーザセンサの制限により ノイズが含まれるという問題がある.ノイズを含む点群を直接扱うことは、三次元点群の物体検 出やセグメンテーションなどの後段タスクにおいて、処理精度の低下を引き起こす可能性がある. そのため、コンピュータビジョンの分野において、点群ノイズ除去は重要な技術となっている.

1.2 関連研究と問題点

点群とは、三次元空間における物体形状を、その表面上の観測点の直交座標(x,y,z)で表現した データ形式である. 点群ノイズ除去は、点群データに含まれるノイズの検出や補正が目的とされ、 データの前処理として適用される技術である. 長年に渡り、Bilateral Filter [4] や Moving Least Squares [5] が研究されており、近年では深層学習を用いた点群ノイズ除去手法が登場している.

深層学習を用いた点群ノイズ除去とは、大量のノイズを含む点群データとそれに対応するクリーンな点群データを用いて学習したモデルを利用し、ノイズの混入した点群データを綺麗にする技術である. 従来の数学的な手法と比較して、未知の点群データに対してもノイズを効果的に処理することが可能となっている.

深層学習を用いた代表的なモデルには、ベクトル推定を用いた手法の PointCleanNet [6] やスコ ア推定を用いた手法の Score-Based Point Cloud Denoising [7] が挙げられる.

PointCleanNetは、外れ値検出とノイズ除去を行うために設計されたモデルである。PointNet [8] の特徴抽出手法を活用し、各点に対してノイズが低減する方向にベクトルの推定を行う。また、グラフ畳み込みネットワークが導入された点群ノイズ除去手法(以降、Graph-Based PointCleanNet [9]) も登場している。この手法では、グラフ畳み込み層の導入によって点の関係性を考慮した計算が可能となり、PointCleanNetの問題を解決している。しかし、精度向上に貢献している反面、処理時間の増加が懸念されている。また、PointCleanNetと比較して平面や曲面部分の改善は著しい反面、エッジ部分における平滑化の問題が残っている。 Score-Based Point Cloud Denoising は、ノイズ除去を目的として点群の局所空間におけるスコ アを推定するために設計されたモデルである。局所空間の分布をモデルとして、高確率の領域に スコアが推定されるように学習が行われる。三次元形状表現の潜在空間を絞り込むことができる ため、ベクトル推定を用いた手法と比較して、外れ値を含む領域や密度の低い領域に対しても有 効的な処理が可能となっている。しかし、局所空間における点数を固定しているため、外れ値や 密度の変化を十分に考慮せず学習が行われてしまうという問題がある。

そこで本研究では、ベクトル推定およびスコア推定を用いた各モデルの問題点に対する改善手法 を提案する. Graph-Based PointCleanNet について、処理時間の増加に関する問題には、グラフ 畳み込みネットワークの改良により、処理時間を抑えるレイヤー設計手法を適用する.また、エッ ジ部分の平滑化に関する問題には、主成分分析を用いてエッジ領域における点の移動を抑制する 手法を提案する. Score-Based Point Cloud Denoising について、外れ値や密度の変化を考慮でき ていない問題には、統計的手法を用いて学習時の近傍点数を動的化する手法を提案する.

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 従来の点群ノイズ除去手法および関連技術について述べる.

第3章 ベクトル推定を用いた手法に対する提案内容,実験内容および考察について述べる.

第4章 スコア推定を用いた手法に対する提案内容,実験内容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.

5

第2章 関連研究

2.1 まえがき

本章では、従来の点群ノイズ除去手法および関連技術について述べる.

はじめに,第3章で扱うベクトル推定を用いた点群ノイズ除去の先行研究として,PointCleanNet および Graph-Based PointCleanNet の仕組みを説明する.また,提案手法に関連する技術として Dynamic Graph CNN [10] および Optimized-Graph CNN [11] について述べる.

次に,第4章で扱うスコア推定を用いた点群ノイズ除去の先行研究である Score-Based Point Cloud Denoising の仕組みを説明した後,提案手法に関連する技術として PointPillars [12] について述べる.

2.2 PointCleanNet

PointCleanNet (図 2.1) は、畳み込みニューラルネットワークを用いた点群ノイズ除去手法で あり、外れ値検出を行う Outlier Detector とノイズ補正を行う Denoiser から構成される. Outlier Detector では、外れ値を持つ点群 P' の局所パッチ 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 $\hat{\mathbb{P}}$ 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 の二つのネットワークは,それぞれ Quaternion Spatial Transform Network(QSTN), Spatial Transform Network(STN),および Feedforward Neural Network(FNN) 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する.

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 τ 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。

$$o_i \in \mathbb{O}$$
: if $\tilde{o}_i > \tau$ (2.1)

さらに,式 (2.2) により外れ値を取り除いた点群 ℙ が得られる.ここで, \ は集合の差を表す記 号であり, *A* \ *B* は集合 *A* から集合 *B* の要素を取り除く計算を行う.

$$\hat{\mathbb{P}} = \mathbb{P}' \setminus \tilde{\mathbb{O}} \tag{2.2}$$

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.

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

2.2.2 Denoiser

Denoiser は、ノイズ補正を行うネットワークである. Denoiser では、Outlier Detector で外れ値 を取り除いた後の集合 $\hat{\mathbb{P}}$ 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) によりノイズ補正された滑らかな点群 $\tilde{\mathbb{P}}$ が得られる. ここで、+ は ノイズ点の座標 $\hat{\mathbb{P}}$ を補正ベクトル $f(\hat{\mathbb{P}})$ で移動させる操作を表す.

$$\mathbb{P} = \mathbb{P} + f(\mathbb{P}) \tag{2.4}$$

損失関数には、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.

$$L_{s}(p_{i}, \mathbb{P}_{p_{i}}) = \min_{p_{j} \in \mathbb{P}_{p_{i}}} \|\tilde{p}_{i} - p_{j}\|_{2}^{2}$$
(2.5)

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

Denoiser の損失関数を式 (2.7) に示す.

$$L_{\alpha}(p_i, \mathbb{P}_{p_i}) = \alpha L_s + (1 - \alpha)L_r \tag{2.7}$$

ここで、QSTN により回転動作を施した点群は正準空間上の座標として表現される.そのため、 正準空間でノイズ除去を行った後、QSTN の出力の逆数をかけて世界空間上の座標表現に戻すた めの逆回転を行う必要があることに注意する.

2.3 Graph-Based PointCleanNet

Graph-Based PointCleanNet(図 2.2)は、グラフ畳み込みネットワークを用いた点群ノイズ除 去手法である.グラフ畳み込み層は、Dynamic Graph CNN を基に構成されており、各レイヤー の前で各注目点に対して K-NN 探索を行い近傍点を探索する.そして、注目点から近傍点までの 距離を計算することで、近傍点グラフの構築を行う.その後、注目点と近傍点グラフの両方を入 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、局所部分の幾何学的構造を反映した計算が行える.

このモデルでは、膨大な処理時間がかかることに加え、エッジ部分の平滑化の問題が課題である. 各ネットワークは、Quaternion Spatial Transform Network, Graph Convolutional Layer, Residual Block から構成される.



図 2.2 Graph-Based PointCleanNet のモデル構造

2.4 Score-Based Point Cloud Denoising

Score-Based Point Cloud Denoising (図 2.3) は、ノイズ除去を目的として点群データの局所空 間におけるスコア(確率密度関数の対数勾配)を推定する手法である.本手法は点群の分布をモ デル化し、高確率領域へのベクトル推定を行うことで、外れ値や低密度領域を含む点群に対して も効果的なノイズ除去を実現する.これにより、既存のベクトル推定手法と比較して、三次元形 状の復元精度が向上する.しかし、局所空間における点数が固定されているため、外れ値や密度 の変動を十分に考慮できないという課題がある.



図 2.3 Score-Based Point Cloud Denoising のモデル構造

以下に,モデルを構成する特徴抽出ユニットおよびスコア推定ユニットについて説明する.

2.4.1 Feature Extraction

Feature Extraction は、入力点群 $X = \{x_i\}_{i=1}^N$ から各点の特徴を抽出する役割を担う.具体的には、動的グラフ畳み込みネットワークを複数層用いることで、各点の局所特徴および非局所特徴をマルチスケールで学習する。このアプローチは、ノイズ除去タスクにおいて高い有効性が示されており、本研究においても点群のロバストな特徴抽出を可能にしている。点 x_i に対応する学習された特徴ベクトルは h_i と表される。

2.4.2 Score Network

Score Network は,点 x_i の特徴ベクトル h_i と局所座標 $x \in \mathbb{R}^3$ を基に,スコア関数 $S_i(x)$ を 推定するユニットである.このスコア関数は、ノイズを含む点群における点 x が高確率領域へ向 かうベクトル場を表現する.スコア関数 $S_i(x)$ は式 (2.8) で定義される.

$$\mathcal{S}_i(x) = \mathrm{MLP}(x - x_i, h_i) \tag{2.8}$$

ここで、MLP の入力には、相対座標 $x - x_i$ および学習された特徴 h_i を利用する.スコア推定 は、式 (2.9) に示す目的関数を最小化することで、局所分布の確率密度関数に対する対数勾配を近 似する.

$$\mathcal{L}^{(i)} = \mathbb{E}_{x \sim \mathcal{N}(x_i)} \left[\| s(x) - \mathcal{S}_i(x) \|_2^2 \right]$$
(2.9)

ここで、s(x) は真のスコア関数を示し、 $\mathcal{N}(x_i)$ は点 x_i を中心とする局所分布である.

2.5 Dynamic Graph CNN

Dynamic Graph CNN(図 2.4)は、点群の分類とセグメンテーションを行う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各レイヤーの前で Edge Conv を行った後、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とは, 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ネットワークである.



図 2.4 Dynamic Graph CNN のモデル構造

2.6 Optimized Graph CNN

Optimized Graph CNN では、点群処理におけるグラフ畳み込みネットワークの計算効率向上 を目的とした議論が行われている。特に、グラフ畳み込みについて数学的に解析されており、二 つのことが証明されている。一つ目は、三次元点群の局所的な幾何学構造情報がグラフ畳み込み ネットワーク内で滑らかに伝播するという特性である。この特性により、K 近傍探索を毎回行う 必要がなくなり、最初の近傍探索結果を複数の層で共有し、受容野を徐々に拡大するアプローチ を可能にする。

この特性は式 (2.10) で表現される.

$$\sigma^{2} K^{2} \left\| \frac{1}{K} \sum_{k=1}^{K} x_{i}^{k} - \frac{1}{K} \sum_{k=1}^{K} x_{j}^{k} \right\|_{2}^{2} \leq \mathbb{E} \left[\left\| x_{i}' - x_{j}' \right\|_{2}^{2} \right] \leq \sigma^{2} dKM \sum_{k=1}^{K} \left\| x_{i}^{k} - x_{j}^{k} \right\|_{2}^{2}$$
(2.10)

ここで, x_i^k は点 x_i の k 番目の近傍点であり, σ^2 はパラメータ分布の分散を表す. この不等式 は,入力空間における近傍点の幾何的な近接性が出力空間にも保存されることを示す.

二つ目は、グラフ特徴収集操作と MLP の順序を入れ替えることで計算負荷を大幅に削減できる 特性である.順序の変更により、特徴量の次元拡張を回避できるため、計算負荷が軽減される.

以上のアプローチにより、グラフ畳み込みネットワークの計算効率を向上させつつ、精度を維 持することが可能となる.

2.7 PointPillars

PointPillars は、車載 LiDAR で取得された点群から物体を検出するために設計されたモデルで ある.この手法では、地面の方向が既知であることを利用して、点群を小さな柱状の領域に分割 する.そして、各領域から特徴量を計算して Bard' Eye View [13] の二次元画像に投影した後、そ の画像を入力として特徴を抽出し物体検出を行う.この際、各領域は異なる数の点を含むため、特 徴行列を一定のサイズに揃える必要がある.この際、点数が多い場合にはランダムサンプリング で点が選択される.また、点数が少ない場合にはゼロ埋め込みを用いて領域内の点数を統一する.

具体的には,各 pillar に含まれる点群の特徴を行列 $X \in \mathbb{R}^{N \times d}$ として定義する.ただし,N は pillar 内の最大点数, d は各点の特徴次元を表す.点数が N に満たない場合,式 (2.11) のように ゼロ埋め込みを適用する.

$$X_{\text{padded}} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_M \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \text{ where } M < N, \ x_i \in \mathbb{R}^d, \ 0 \in \mathbb{R}^d$$
(2.11)

この操作により、行列のサイズを統一し、後続のニューラルネットワーク処理に適した形式に 整えることができる. ゼロ埋め込みにより追加される要素は学習に影響を与えず、計算効率を向 上させる点で重要である. この方法を採用することで、PointPillars は点群の効率的なデータ表現 と計算を実現している.

2.8 むすび

本章では、第3章のベクトル推定を用いた点群ノイズ除去の先行研究である PointCleanNet および Graph-Based PointCleanNet, 関連技術として Dynamic Graph CNN および Optimized-Graph CNN について述べた.また、第4章のスコア推定を用いた点群ノイズ除去の先行研究である Point Cloud Denoising, 関連技術として PointPillars について述べた.

3.1 まえがき

本章では、先行研究の Graph-Based PointCleanNet に対する二つの提案手法について説明した 後、実験条件、実験結果、考察を述べる.一つ目は、モデルの処理時間の増加を抑えるための効 率的なグラフ畳み込み層の設計手法である.二つ目は、エッジの平滑化に対して主成分分析を用 いてエッジ領域における点の移動を抑制する手法である.

3.2 提案手法

3.2.1 効率的なグラフ畳み込み層の設計手法

従来のグラフ畳み込み層では処理時間が増加する問題に対して,グラフ畳み込みの最適化を目 的とした提案を行う.二種類のグラフ畳み込み層におけるモデル構造の違いを図 3.1 に示す.



(a) Conventional Method: Normal Graph Convolutional Layers



(b) Proposed Method: Optimized Graph Convolutional Layers

図 3.1 二種類のグラフ畳み込み層におけるモデル構造の違い

図 3.1(a) は従来手法の Graph-Based PointCleanNet におけるグラフ畳み込み層である. この手法は, Dynamic Graph CNN に基づいており,各局所特徴ネットワークごとに動的に近傍点グラフを更新するように設計されている. 従来手法のグラフ畳み込み層を式 (3.1) に示す.

$$x'_{i} = \sum_{k=1}^{K} f(x_{i}^{k} - x_{i}, \Theta)$$
(3.1)

図 3.1(b) は提案手法のグラフ畳み込み層である.提案手法は、グラフ畳み込みの効率化に関す る先行研究に基づいており、近傍点グラフを固定した計算が行われる.具体的には、低次元空間 で構築された近傍点グラフを後続レイヤーで共有する仕組みを採用することで、計算コストを削 減しつつグラフ畳み込みの性能を維持している.提案手法のグラフ畳み込み層を式 (3.2) に示す.

$$x_i' = \sum_{k=1}^K f(x_i^k, \Theta) - f(x_i, \Theta)$$
(3.2)

ここで, x'_i は点 *i* における更新後の特徴量, x^k_i は点 *i* の *k* 番目の近傍点に対応する特徴量, x_i は点 *i* 自身の特徴量を表している. また, *K* は近傍点の探索数, $f(\cdot)$ は MLP として設計された 非線形変換関数, Θ は学習可能なパラメータである.

3.2.2 主成分分析を用いたエッジの移動抑制

エッジが過剰に平滑化してしまう問題に対して,エッジの移動抑制を目的とした提案を行う. まず,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) ,法線ベクトル n_i を式 (3.3)で定義する.

$$n_i = \begin{pmatrix} a \\ b \\ c \end{pmatrix} \tag{3.3}$$

次に,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 (3.4) で近似される.

$$a(x - \bar{x}) + b(y - \bar{y}) + c(z - \bar{z}) = 0$$
(3.4)

以上を基に,平面方程式における係数 d は式 (3.5) で表される.

$$d = -a\bar{x} - b\bar{y} - c\bar{z} \tag{3.5}$$

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.距離 r およびエッジ判定処理を,それぞれ式 (3.6),式 (3.7) に示す.

$$r = \frac{|ax_0 + by_0 + cz_0 + d|}{\sqrt{a^2 + b^2 + c^2}}$$
(3.6)

$$p_i \in E: \text{ if } r \ge \tau \tag{3.7}$$

また、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、m 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.

提案手法における補正ベクトルの判別方法を,式(3.8)および図3.2に示す.

$$p_i + ld_i \ (0 \le i \le m): \text{ if } p_i \in E \tag{3.8}$$



図 3.2 主成分分析を用いた点群データのエッジ判別手法

3.3 実験条件

3.3.1 データセット

外れ値検出タスクには、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、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、および 0.5%、1.0%、2.5%のガウスノイズ を持つ 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、および点群のサイズを 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.

ノイズ除去タスクには,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,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,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.

3.3.2 評価指標

外れ値検出精度の評価には、AUPR を使用する. AUPR は、テスト結果の再現率と適合率の変 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.

ノイズ除去精度の評価には,式 (3.9) で表される Chamfer-Distance [14] を使用する.

Chamfer-Distance =
$$\frac{1}{N} \sum_{\boldsymbol{p}_i \in \tilde{P}} \min_{\boldsymbol{p}_j \in P} \|\boldsymbol{p}_i - \boldsymbol{p}_j\|_2^2 + \frac{1}{M} \sum_{\boldsymbol{p}_j \in P} \min_{\boldsymbol{p}_i \in \tilde{P}} \|\boldsymbol{p}_j - \boldsymbol{p}_i\|_2^2$$
(3.9)

Chamfer-Distance は、各ノイズ除去点 \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除去点 \tilde{p}_i との間の平均距離の合計である.ここで N, M は、それぞれノイズ処理点 \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. Chamfer-Distanceの概略図を図 3.3 に示す. 矢印は,予測点および正解データ点から互いに最も近い点までの空間的距離を表している.



図 3.3 Chamfer-Distance の概略図

3.4 評価実験

3.4.1 グラフ畳み込み層の最適化によるモデル性能と処理時間への影響

従来手法の PointCleanNet, Graph-Based PointCleanNet および提案手法の性能評価を目的と した実験を行う.具体的には、グラフ畳み込み層の最適化がモデルの性能と処理時間に与える影響を評価する.

外れ値検出精度の評価には、PointCleanNet 外れ値データセットを使用し、AUPR で定量的に評価した.また、ノイズ除去精度の評価には、PointCleanNetノイズデータセットを使用し、Chamfer-Distance で定量的に評価した。AUPR による外れ値検出精度の評価を表 3.1、Chamfer-Distance によるノイズ除去精度の評価を表 3.2 に示す.さらに、二つのグラフ畳み込み層の性能を比較するため、Outlier Detector と Denoiser の処理時間の比較を表 3.3 に示す.

最後に、モデル全体の性能を評価する.評価には正二十面体の形状の点群に対して、形状領域の 対角線上に標準偏差 20%のガウスノイズを付与したデータを使用する.そのうち、標準偏差 1.5% より表面から離れた点の 30%は外れ値として変換されている.従来手法と提案手法におけるモデ ル全体の評価を表 3.4 に示す.また、定性的な評価結果を図 3.4 に示す.

Madal		Gaussian I	Noise Level	
Model	0%	1.0%	1.5%	2.5%
PointCleanNet	0.957	0.858	0.781	0.659
Graph-Based PointCleanNet	0.972	0.906	0.821	0.670
Proposed Method	0.969	0.902	0.805	0.665

表 3.1 AUPR による外れ値検出精度の評価

Madal	Gaussian Noise Level				
Wodel	1.0%	1.5%	2.5%		
PointCleanNet	0.0123	0.0224	0.137		
Graph-Based PointCleanNet	0.0109	0.0189	0.127		
Proposed Method	0.0111	0.0208	0.134		

表 3.2 Chamfer-Distance によるノイズ除去精度の評価

表 3.3 Outlier Detector と Denoiser の処理時間(1点)の比較

Model	Outlier Detector (s)	Denoiser (s)
Graph-Based PointCleanNet	2.57×10^{-4}	2.38×10^{-4}
Proposed Method	$2.21 imes10^{-4}$	$2.07 imes10^{-4}$

表 3.4 従来手法と提案手法におけるモデル全体の評価

Model	Chamfer-Distance	Time (s)
PointCleanNet	1.56×10^{-4}	—
Graph-Based PointCleanNet	$1.03 imes10^{-4}$	5.02×10^{-4}
Proposed Method	1.04×10^{-4}	$4.35 imes10^{-4}$



図 3.4 正二十面体に対する点群ノイズ除去の定性的評価 (従来手法1:PointCleanNet, 従来手法2:Graph-Based PointCleanNet)

3.4.2 エッジの移動抑制によるノイズ除去精度への効果

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%の大きさとした。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 刻みで比較を行うこととする。 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3.5 に示す。また、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なった定性的な評価結果を図3.5 に示す。

经妻毛计				提案	手法(係	数 l)			
促苯于伍	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
1.151	1.176	1.161	1.138	1.132	1.118	1.121	1.132	1.138	1.142
							1		7
and the second								and the second second	
		*	1	-	-	-	_	-	_
(a) 入力点群	羊	l = 0.2	2	l = 0.5	2	l=0.	8	(l = 1)	1)
	C	$D = 1.176 \times$	10^{-2} (D = 1.118	<10 ⁻²	CD = 1.138	3×10^{-2}	CD = 1.15	1×10^{-2}
				(b) 提案书	戶法			(c) 従来	手法

表 3.5 係数 l を変化させた際の Chamfer-Distance $(\times 10^{-2})$ による評価

3.4.3 考察

3.4.1 では、グラフ畳み込み層の最適化によるモデル性能と処理時間への影響について評価した. 表 3.1 に示した外れ値検出精度の評価より、提案手法は各ノイズレベルにおいて PointCleanNet よりも AUPR を向上させるとともに、Graph-Based PointCleanNet に次ぐ性能を発揮すること が確認できた.表 3.2 に示したノイズ除去精度の評価より、提案手法は各ノイズレベルにおいて PointCleanNet よりも Chamfer-Distance を低減するとともに、Graph-Based PointCleanNet に次 ぐ性能を発揮することが確認できた.

また、表 3.3 では、モデルを構成する Outlier Detector と Denoiser での各処理時間について評価 した。結果から、1 点を処理する時間に関して、提案手法の Outlier Detector では 0.36×10^{-4} 秒, Denoiser では 0.31×10^{-4} 秒短縮させることを示した。そのため、本実験で使用した 100 万点で構成される点群データを処理する場合、Graph-Based PointCleanNet と比較して提案手法の Outlier Detector では 36 秒、Denoiser では 31 秒早く処理可能なモデルを設計できたことがわかる。

さらに、表 3.4、図 3.4 から、モデル全体の性能においても Chamfer-Distance を低減し定性的 にも優れた処理が行えていることがわかる.以上から、提案手法は PointCleanNet の性能を凌駕 するだけでなく、処理時間を削減しながらも Graph-Based PointCleanNet と同等の性能を示すこ とが確認できた.したがって、処理時間を削減しながらもノイズ除去精度を維持できる提案手法 は、今後利用が加速する自動運転のためのデジタル地図やインフラの点検等の大規模な点群処理 において非常に有効的であることが推測できる.

3.4.2 では,エッジの移動抑制によるノイズ除去精度への効果について評価した.表3.5 より,提 案手法では0.1,0.2 の場合を除いて従来手法のノイズ除去精度を低減できたことが確認できる.特 に,係数 *l* の値を0.5 に設定した場合が最も良い性能となった.この結果は,図3.5 からも確認で

図 3.5 係数 *l* の変化に伴うエッジの定性的評価(従来手法:Graph-Based PointCleanNet)

き,係数を変化させた際に係数 *l* が 0.2 では除去が足りず,0.5 で最も綺麗なエッジの形状となり,0.8 では過剰に平滑化していることがわかる.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.この結果から,0.3 と 0.8 の場合では,Chamfer-Distanceの値が同じでも形状が大きく異なる可能性が推測できるため,定性的な評価が非常に重要となる.

3.5 むすび

本章では、ベクトル推定を用いた点群ノイズ除去において、従来手法の問題点に対する二つの 提案手法、実験に用いたデータセット、評価指標について述べた. グラフ畳み込みの効率化では、 AUPR と Chamfer-Distance の二つの評価指標で優れた精度を達成するとともに、処理時間を削 減できた. また、エッジの移動抑制では、Chamfer-Distance で優れた精度を達成し、定性的な評 価でもエッジの鋭さを保持し有効性を示すことができた.

4.1 まえがき

本章では、先行研究の Score-Based Point Cloud Denoising に対する予備実験、提案手法、実験 条件、実験結果、考察について述べる.まず、予備実験として、点群データの分散を解析し、先 行研究では空間的な距離を考慮できていないことを示す.次に、提案手法として、学習時の近傍 点数を動的化し、外れ値や密度の変動に対応する手法について述べる.また、実験条件について、 本実験で用いたデータセット、損失関数、評価指標について述べる.最後に、評価実験として複数 のノイズ点群をモデルに入力した際の結果を比較し、考察を述べる.

4.2 予備実験

予備実験として,後述する PU-Net データセットから,近傍点数を従来手法における学習時と 同じ 32 に設定し,ランダムに抽出した 1728 個の集合を用いて分散を求めた.その結果,図 4.1 に 示す割合となり,近傍中の分散を統計的に示すことができた.予備実験の結果から,先行研究で は近傍点数を固定しているため,距離が極端に遠い場合にも近傍として処理している可能性が示 唆された.すなわち,従来手法では点群の空間的距離を考慮できないまま学習しているという問 題が明らかになった.





4.3 提案手法

提案手法では、分散が大きい集合から均等に近傍点数を4,8,16,32と分類しモデルを学習する. すなわち、ノイズ点群の分散に応じて近傍点数を動的に変化させる処理を行えるようにする.こ の仕組みにより、注目点から遠い点の情報を省き、近傍点を制限することで、特徴抽出とスコア の計算をより安定して行えるようになる.

この際,行列のサイズを近傍点数の最大値である 32 に合わせて統一するため,点数が 32 に満たない場合にはゼロ埋め込みを行う.この操作により追加される要素は学習に影響を与えず,計算効率を向上させる.提案手法を図 4.2 に示す.



Zero Padding: if k < 32

図 4.2 学習時における近傍点数の動的化処理

ここで, $S_i(x)$ はスコアネットワークで推定された局所スコア, s(x) は対応する正解スコアであり,目的関数 \mathcal{L}_i を最小化することで学習を行う.

4.4 実験条件

4.4.1 データセット

本実験では,各形状 100000 点および 50000 点を持つ 60 種類の点群からなる PU-Net [15] 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 40 種類の形状において境界領域の対角線の 1.0%, 2.0%, 3.0%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 20 種類の形状において境界領域の対角線の 1.0%, 2.0%, 3.0%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.

また,視覚的な評価として,レーザースキャナーを使って実世界から取得した Paris-rue-Madame データセット [16] を用いる.データセットには,rue Mézières と rue Vaugirard の間の約 160m の 渡る約 35 万点データが含まれている.

4.4.2 評価指標

評価指標には,式(3.9)で示した Chamfer-Distance に加え,式(4.1)で表される Point-to-Surface Distance [17] を使用する.

$$\mathcal{P}(\tilde{P}, \mathcal{S}) = \frac{1}{|\tilde{P}|} \sum_{p \in \tilde{P}} \min_{q \in \mathcal{S}} \|p - q\|_2$$
(4.1)

Point-to-Surface は、ある点群 \tilde{P} と基準となる表面 S の間の距離を計算する指標である. この距離は、点群 \tilde{P} の各点 p に対して、基準表面 S 上の最も近い点 q を見つけ、その間の距離を測定する. この指標により、点群全体が基準表面にどれだけ近いかを定量的に評価できるため、ノイズ除去や表面再構築のタスクに適している.

4.5 評価実験

4.5.1 近傍点数の動的化によるノイズ除去精度への効果

評価実験では,10000点の点群形状の対角線に対して1.0%,2.0%,3.0%のガウスノイズを付与 した PUNet データセットを用いた.ノイズ除去精度の定量的な評価結果を表4.1,表4.2 に示す. また,定性的な評価について,ガウスノイズ1.0%,2.0%,3.0%のkitten データに対するノイズ 除去精度の比較をそれぞれ図4.3,図4.4,図4.5 に示す.

また、Paris-rue-Madame データセットを用いた定性的な評価結果を図 4.6 に示す.

表 4.1 点群ノイズ除去精度の評価 (Chamfer-Distance (×10⁻⁴), 10K Points)

Mathad	Gaus	sian Noise	Level
Method	1.0%	2.0%	3.0%
従来手法	3.12	4.42	6.31
提案手法	3.07	4.24	5.74

表 4.2 点群ノイズ除去精度の評価 (Point-to-Surface (×10⁻⁴), 10K Points)

Method	Gaussian Noise Level		
	1.0%	2.0%	3.0%
従来手法	1.01	1.79	3.27
提案手法	0.92	1.68	2.82



図 4.3 ガウスノイズ 1.0%の kitten データに対するノイズ除去精度の定性的評価



 $CD=3.69\times10^{-4}$ P2M=1.39×10⁻⁴

CD=3.26×10⁻⁴ P2M=1.06×10⁻⁴

図 4.4 ガウスノイズ 2.0%の kitten データに対するノイズ除去精度の定性的評価



図 4.5 ガウスノイズ 3.0%の kitten データに対するノイズ除去精度の定性的評価



図 4.6 Paris-rue-Madame データに対する定性的評価

4.5.2 考察

4.5.1 では、近傍点数の動的化によるスコア推定ネットワークへの効果を評価した.表4.1 より、 点群の類似度を評価する Chamfer-Distance において、各ガウスノイズにおける点群ノイズ除去精 度を低減できたことが確認できる.特に、付与するガウスノイズが1.0%の場合には0.05、2.0%の 場合には0.18、3.0%の場合には0.57のスコア低減を達成した.また、表4.2 から、表面再構築の 性能を評価する Point-to-Mesh においても、各ガウスノイズにおける点群ノイズ除去精度を低減 できたことが確認できる.特に、付与するガウスノイズが1.0%の場合には0.09、2.0%の場合には 0.11、3.0%の場合には0.45のスコア低減を達成した.

加えて,図4.3,図4.4,図4.4からも各ノイズレベルごとのノイズ除去精度が定性的に比較で きる.結果から,ガウスノイズレベルが大きくなるほど従来手法と比較してエッジや曲面におけ る精度改善の幅が大きいことが確認できる.したがって,局所空間における点の分散が大きくな るほど提案手法の有効性が顕著に現れることが示された.

4.6 むすび

本章では、スコア推定を用いた点群ノイズ除去に対する提案手法、予備実験、モデルの学習に 用いたデータセット、実験条件について述べた.また、評価実験として、各ガウスノイズレベル における PU-Net データセットに対して定量的に評価した.さらに、ノイズの異なるデータや実 環境データをモデルに入力した際の従来手法と提案手法の詳細な比較を示した.提案手法では、 Chamfer-Distance およ Point-to-Surface で優れた精度を達成し、定性的な評価でも有効性を示す ことができた.

第5章 結論

5.1 結論

本研究では、点群ノイズ除去モデルの精度改善を目的として、理論的に従来手法の課題を解決 する新しいアプローチを提案した.提案手法では、グラフ畳み込みネットワークの最適化、主成 分分析を用いたエッジ移動の抑制、分散に基づく近傍点数の動的化を示した.従来のグラフ畳み 込みネットワークでは、各層毎に動的な近傍探索を行うことで計算コストが増大する問題が指摘 されていたが、本研究では近傍点グラフを固定する設計を適用することで精度を維持しつつ処理 時間を大幅に改善した.特に、従来手法の Graph-Based PointCleanNet と比較して最大13.3%の 処理時間短縮を実現するとともに、同等の外れ値検出精度およびノイズ除去精度を示した.

さらに、主成分分析を用いたエッジ移動抑制手法を導入することで、エッジ形状を保持しなが ら過剰な平滑化を防ぐことが可能となった.これにより、Chamfer-Distanceの低減に加え、定性 的なノイズ除去精度の向上を示した.

また, Score-Based Point Cloud Denoising において外れ値や密度の変動を十分に考慮していな い問題に対して,点群データの分散に基づいて近傍点数を動的に調整する仕組みを提案した.この 手法は遠距離の点の影響を効果的に軽減し,計算の安定性を確保しながら,従来手法を最大13.8% 上回る性能を示した.評価実験では,仮想的に生成されたデータセットだけでなく,実世界のス キャンデータに対しても有効性を確認し,提案手法の実用性を示した.

5.2 今後の課題

提案手法には、いくつかの課題が残されている.まず、グラフ畳み込み層の更なる計算効率の 向上を目指すためには、低次元空間における近傍点グラフの新たな活用法を見出し、近傍点と点 群特徴を分離して処理する新しいアプローチが有望である.次に、エッジ判定処理の閾値 τ を形 状の対角線の7.5%の大きさと設定しているが、割合を定量的に調査する必要がある.また、本研 究では主に仮想的に作成した点群データをに使用しているため、実世界の複雑な点群データを増 やして詳細に検証する必要がある.特に、都市環境や自然景観といった多様な実環境データでの 性能評価を行うことで、提案手法における汎用性と信頼性のさらなる向上が求められる.

加えて、ノイズ除去以外の点群処理タスクへの応用も重要である。例えば、セグメンテーションや物体検出に適用させ、エッジや曲面における識別精度を調査する必要がある。さらに、RGB 画像やLiDAR データとのマルチモーダル統合を進めることで、より高精度なノイズ除去や形状推定の実現が可能となると考えられる。

謝辞

本論文の執筆にあたり、日々のゼミ活動を通じて研究の方向性や課題についてご指導いただき、 また快適な研究環境を整えてくださった渡辺裕教授に深く感謝申し上げます.

また,毎週のチームゼミ活動において,研究の進捗や実験条件について丁寧なアドバイスを賜 りまし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心より感謝いたします.

さらに、多岐にわたる研究領域を共有していただき、日頃から温かく接してくださった渡辺研 究室の皆様に深く感謝申し上げます.

最後に、これまで私を育てていただき、早稲田大学での学業、サークル活動、そして研究生活 を支えてくださった家族に心から感謝いたします.

参考文献

- Zhongyang Xiao, Diange Yang, Tuopu Wen, Kun Jiang, and Ruidong Yan: "Monocular Localization with Vector HD Map (MLVHM): A Low-Cost Method for Commercial IVs," Sensors 2020, 20(7), 1870, Mar. 2020.
- [2] Kaiwen Guo, Peter Lincoln, Philip Davidson, Jay Busch, Xueming Yu, Matt Whalen, Geoff Harvey, Sergio OrtsEscolano, Rohit Pandey, Jason Dourgarian, Danhang Tang, Anastasia Tkach, Adarsh Kowdle, Emily Cooper, Mingsong Dou, Sean Fanello, Graham Fyffe, Christoph Rhemann, Jonathan Taylor, Paul Debevec, and Shahram Izadi: "The relightables: Volumetric performance capture of humans with realistic relighting," ACM Transactions on Graphics, 38(6), Nov. 2019.
- [3] Epic Games, Inc.: "Announcing MetaHuman Creator: Fast, High-Fidelity Digital Humans in Unreal Engine," https://www.epicgames.com/, Feb. 2021.
- [4] J. Digne and C. Franchis, "The Bilateral Filter for Point Clouds," Image Processing On Line (IPOL), pp.278-287, Jul. 2017.
- [5] M. Alexa, J Behr, D. Cohen-Or S. Fleishman, D. Levin, and C.T. Silva: "Point Set Surfaces," VIS '01: Proceedings of the conference on Visualization '01, pp.21-28, Oct. 2001.
- [6] Marie-Julie Rakotosaona, Vittorio La Barbera, Paul Guerrero, Niloy J Mitra, and Maks 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.
- [7] Shitong Luo and Wei Hu: "Score-Based Point Cloud Denoising," 2021 IEEE International Conference on Computer Vision, pp.4583-4592, Oct. 2021.
- [8] Charles R Qi, Hao Su, Kaichun Mo, and Leonidas J Guibas: "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation," 2017 IEEE Conference on Computer Vision and Pattern Recognition, pp.77-85, Jul. 2017.
- [9] Kosuke Nakayama, Hiroto Fukuta and Hiroshi Watanabe: "Point Cloud Denoising and Outlier Detection with Local Geometric Structure by Dynamic Graph CNN," 2023 IEEE Global Conference on Consumer Electronics, OS-AIP, pp.156-159, Oct. 2023.
- [10] Yue Wang, Yongbin Sun, Ziwei Liu, Sanjay E Sarma, Michael M Bronstein, and Justin M Solomon: "Dynamic Graph CNN for Learning on Point Clouds," ACM Transactions on Graphics (TOG), Vol.38, Oct. 2019.
- [11] Yawei Li, He Chen, Zhaopeng Cui, Radu Timofte, Marc Pollefeys, Gregory Chirikjian, and Luc Van Gool: "Towards Efficient Graph Convolutional Networks for Point Cloud Handling," 2021 IEEE/CVF International Conference on Computer Vision, pp.3732-3742, Apr. 2021.

- [12] Alex H. Lang, Sourabh Vora, Holger Caesar, Lubing Zhou, Jiong Yang, and Oscar Beijbom: "PointPillars: Fast Encoders for Object Detection from Point Clouds," 2019 IEEE Conference on Computer Vision and Pattern Recognition, pp.12697-12705, Jun. 2019.
- [13] Jason Ku, Melissa Mozifian, Jungwook Lee, Ali Harakeh, Steven L. Waslander: "Joint 3D Proposal Generation and Object Detection from View Aggregation," 2018 IEEE International Conference on Intelligent Robots and Systems, pp.1-8, Oct. 2018.
- [14] H. Fan, H. Su, and L. Guibas: "A Point Set Generation Network for 3D Object Reconstruction from a Single Image," 2017 IEEE Conference on Computer Vision and Pattern Recognition, pp.2463-2471, Jul. 2017.
- [15] Lequan Yu, Xianzhi Li, Chi-Wing Fu, Daniel Cohen-Or, and Pheng-Ann Heng: "PU-Net: Point Cloud Upsampling Network," 2018 IEEE Conference on Computer Vision and Pattern Recognition, pp.2790-2799, Jun. 2018.
- [16] Andrés Serna, Beatriz Marcotegui, Francois Goulette, and Jean-Emmanuel Deschaud: "Paris-rue-madame database: a 3d mobile laser scanner dataset for benchmarking urban detection, segmentation and classification methods," Conference: 2014 International Conference on Pattern Recognition, Applications and Methods, pp.819-824, Mar. 2014.
- [17] Nikhila Ravi, Jeremy Reizenstein, David Novotny, Taylor Gordon, Wan-Yen Lo, Justin Johnson, and Georgia Gkioxari: "Accelerating 3D deep learning with PyTorch3D," SIG-GRAPH Asia 2020, Vol.10, Dec. 2020.



3.1	AUPR による外れ値検出精度の評価...........................	15
3.2	Chamfer-Distance によるノイズ除去精度の評価	16
3.3	Outlier Detector と Denoiser の処理時間(1 点)の比較	16
3.4	従来手法と提案手法におけるモデル全体の評価..............	16
3.5	係数 <i>l</i> を変化させた際の Chamfer-Distance(×10 ⁻²)による評価	17
4.1	点群ノイズ除去精度の評価 (Chamfer-Distance(×10 ⁻⁴), 10K Points)	21
4.2	点群ノイズ除去精度の評価 (Point-to-Surface(×10 ⁻⁴), 10K Points)	21



2.1	PointCleanNet のモデル構造.............................	6
2.2	Graph-Based PointCleanNet のモデル構造	8
2.3	Score-Based Point Cloud Denoising のモデル構造	8
2.4	Dynamic Graph CNN のモデル構造	9
3.1	二種類のグラフ畳み込み層におけるモデル構造の違い	12
3.2	主成分分析を用いた点群データのエッジ判別手法	14
3.3	Chamfer-Distance の概略図	15
3.4	正二十面体に対する点群ノイズ除去の定性的評価	16
3.5	係数 <i>l</i> の変化に伴うエッジの定性的評価(従来手法:Graph-Based PointCleanNet)	17
4.1	点群ノイズデータにおける近傍集合の分散	19
4.2	学習時における近傍点数の動的化処理..................	20
4.3	ガウスノイズ 1.0%の kitten データに対するノイズ除去精度の定性的評価	21
4.4	ガウスノイズ 2.0%の kitten データに対するノイズ除去精度の定性的評価	22
4.5	ガウスノイズ 3.0%の kitten データに対するノイズ除去精度の定性的評価	22
4.6	Paris-rue-Madame データに対する定性的評価	22

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", 電子情報通信学会総合大会, D-12-35, Mar. 2023.
- [2] Kosuke Nakayama, Hiroto Fukuta and Hiroshi 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] Hiroto Fukuta, Kosuke Nakayama and Hiroshi Watanabe: "Three-Dimensional Baseball Strike Judgement by Monocular Video from Umpire's Viewpoint," IEEE Global Conference on Consumer Electronics, OS-AIP, pp.160-163, Oct. 2023.
- [4] 中山光典, 杉山秀治, 福田大翔, 渡辺裕: "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", 映像情報メディア学会年次大会, 13B-5, Aug. 2024.
- [5] 福田大翔, 中山光典, 杉山秀治, 渡辺裕: "自動ボールストライク判定におけるフロートラッキ ングを用いた処理量削減法", 映像情報メディア学会年次大会, 11A-5, Aug. 2024.
- [6] 杉山秀治, 福田大翔, 中山光典, 渡辺裕: "Class Activation Mapping を用いた視線推定手法の評価および有効性の確認", 映像情報メディア学会年次大会, 11A-4, Aug. 2024.