

# 修士論文概要書

Summary of Master's Thesis

Date of submission: (01/29/2020)

専攻名 (専門分野) Department	情報理工・ 情報通信専攻	氏名 Name	赤塚 紘輝	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	CD 5118F001-8		
研究題目 Title	形状の特徴を考慮した点群のノイズ整形 Noise Shaping of Point Cloud Considering Shape Features				

## 1. まえがき

近年, センサを用いてロボット掃除機や自動運転車など様々な機械の自動化が進められている. それらのセンサの一つとして LiDAR が挙げられる. LiDAR では周囲の 3 次元構造を点群として取得可能である. しかし, 取得点群には必ずノイズが含まれるという問題点がある. ノイズにより点群の位置合わせや物体検出, セグメンテーションなどの処理精度に影響を及ぼし, 十分な処理精度が得られない. したがって, ノイズ整形は点群を扱う上で重要な技術であると考えられる.

本稿では, LiDAR 機器の一つである Velodyne 社製 VLP-16 で取得した点群に対して, 特徴抽出で得られた特徴量をもとにしたノイズ整形手法を提案する.

## 2. 従来手法

### 2.1. 特徴抽出

点群特徴抽出手法として DoN[1], DoC, DDoN, DDoC, RDoN, RDoC[2]及び MS(マルチスケール)特徴[3]が挙げられる. DoN, DoC では注目点において二つの近傍範囲で主成分分析を行うことで法線ベクトル, 近似曲率を二つ算出し, それらの差分を特徴量とする手法である. DDoN, DDoC, RDoN, RDoC は DoN と DoC での近傍範囲の取り方を変えた手法である. また MS 特徴では注目点における近傍範囲を複数変化させ, それぞれに対して主成分分析を行い, 求めた複数の近似曲率が閾値以上である割合を特徴量としている. 従来手法はいずれも複数の近傍範囲設定が必要であり, 適切な近傍範囲設定が困難である.

### 2.2. ノイズ整形

ノイズ整形手法として移動最小二乗法(MLS)[4], APSS[5], RIMLS[6]及び Bilateral[7]が挙げられる. MLS は点群に曲面を合わせ, 各点を曲面に投影することで滑らかな整形を可能としている. APSS では MLS をもとにして低サンプリングレート及び高曲率下での精度を向上させ, RIMLS は MLS と局所カーネル回帰を用いた手法である. Bilateral は画像における 2次元の Bilateral を 3次元拡張したものであり, 注目点と近傍点の距離や局所回帰平面との距離によって重み付けを行い平滑化している. 従来手法はいずれも過度な平滑化をもたらす.

## 3. 提案手法

### 3.1. 特徴抽出

従来手法では複数の近傍範囲を用いている. そこで近傍範囲の一つだけ用いる手法を提案する. 各点において, 主成分分析によって得られた法線から平面方程式を算出し, 近傍範囲内の点群が算出された平面方程式上に存在しない割合を特徴量とする.

入力点群を  $\mathbf{P} = \{\mathbf{p}_i\}_{i=1}^M$ ,  $\mathbf{p}_i \in \mathbb{R}^3$ , それぞれの点に対する近傍点群を  $\mathcal{N}(\mathbf{p}_i) = \{\mathbf{q}_{i,j}\}_{j=1}^{|\mathcal{N}(\mathbf{p}_i)|}$ ,  $\mathbf{q}_{i,j} \in \mathbf{P}$  とする. ここで  $|\mathcal{N}(\mathbf{p}_i)|$  は近傍点群数を表す. 各点の法線ベクトル及び近傍点群重心を  $\mathbf{n}_i$ ,  $\mathbf{g}_i$  とすると, 各点  $\mathbf{p}_i$  の特徴量  $\omega_i$  は

$$\omega_i = \frac{1}{|\mathcal{N}(\mathbf{p}_i)|} \sum_{j=1}^{|\mathcal{N}(\mathbf{p}_i)|} \Omega_{i,j}, \quad \Omega_{i,j} = \begin{cases} 1 & |\mathbf{n}_i^T(\mathbf{q}_{i,j} - \mathbf{g}_i)| \geq \tau \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

と表せる. ここで  $\tau$  は許容誤差範囲である. LiDAR におけるノイズは計測距離に対しての正規分布で表すことができ, 計測位置を原点として各点の距離  $x$  で生じるノイズの標準偏差は  $\sigma = (0.102x + 0.45)/100$  となることがわかっている. 正規分布ではすべてのデータの 99.7% が  $\mu \pm 3\sigma$  以内に分布するという特徴を持つ. よって提案手法の許容誤差範囲は平均が 0 の正規分布に従うと仮定することで  $\tau = 3\sigma$  と自動算出可能である.

### 3.2. ノイズ整形

特徴抽出で得られた各点の近傍点群重心, 法線, 特徴量を用いてノイズ整形を行う. 特徴量で平面部とエッジ部の処理を分ける. 平面部では近傍点群重心及び法線から平面方程式が算出可能なため, その平面上に点群を移動させることでノイズ整形を行う. よって平面部に属する各点  $\mathbf{p}_i$  のノイズ整形後の点  $\hat{\mathbf{p}}_i$  は

$$\hat{\mathbf{p}}_i = \frac{\mathbf{n}_i^T \mathbf{g}_i}{\mathbf{n}_i^T \mathbf{p}_i} \mathbf{p}_i \quad (2)$$

と算出できる. エッジ部は平面部同士に挟まれた部分であると考えられるため, 注目点の持つ法線とコサイン類似度の高い法線を持ち, 特徴量が低い最近傍点を

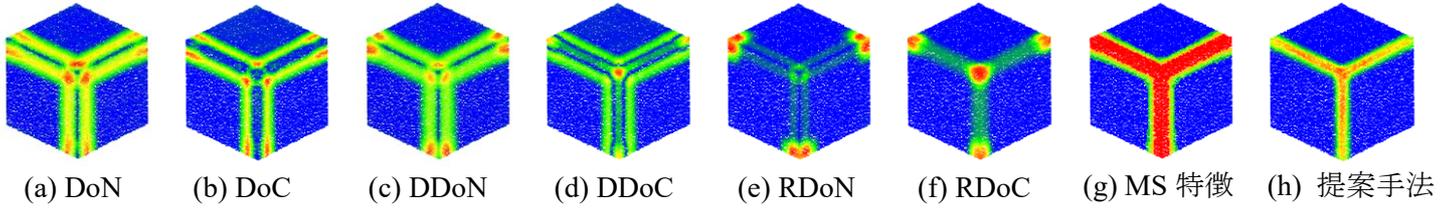


図 1. 特徴抽出結果

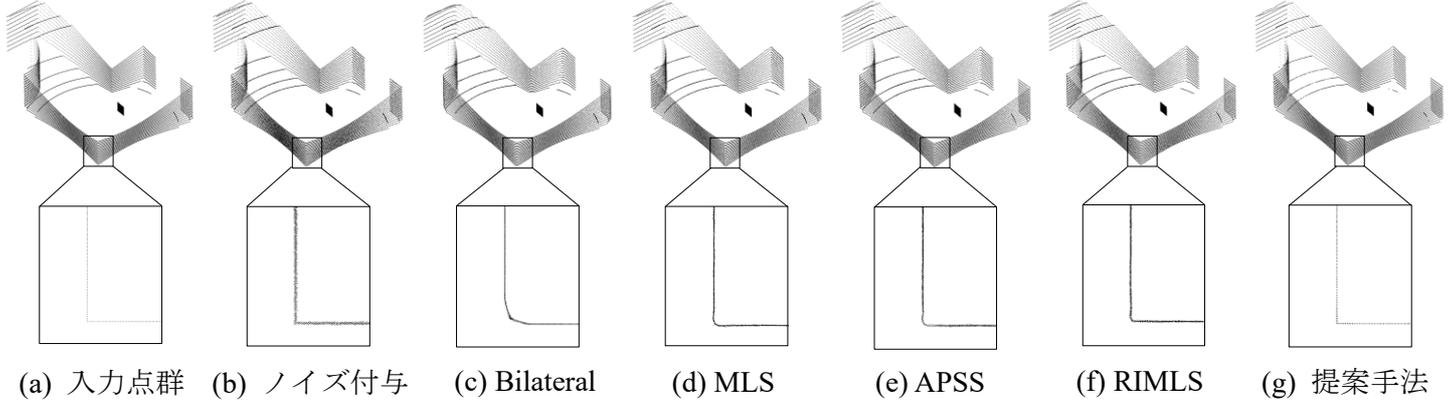


図 2. ノイズ整形結果

用いて算出される平面方程式上に移動させることでノイズ整形を行う。よってエッジ部に属する各点  $p_i$  のノイズ整形後の点  $\hat{p}_i$  は

$$\hat{p}_i = \frac{n_{q_{near}}^T g_{q_{near}}}{n_{q_{near}}^T p_i} p_i \quad (3)$$

と算出できる。ここで  $n_{q_{near}}$  及び  $g_{q_{near}}$  は平面方程式を算出するための近傍点を持つ法線と近傍点群重心である。

ノイズ量は最大でも  $3\sigma$  程度であると考えられるため、整形後の点と元の位置との距離が  $3\sigma$  以上の場合、その点を除去する。

## 4. 評価実験

### 4.1. 特徴抽出

入力点群は 1 辺 50cm の正方形 3 面から構成されたモデルが計測位置から y 方向に +300cm, z 方向に -400cm の位置に存在すると仮定し、ノイズを付与したモデルである。従来手法の近傍範囲は 7.5cm と 15.0cm, MS では 2.5cm ずつ変化させ、近似曲率は 0.04, 提案手法の近傍範囲は 7.5cm とした。得られた特徴量を最大値が赤、最小値を青のヒートマップで図 1 に示す。図 1 より提案手法は従来手法よりもエッジを細部に抽出していることが確認できる。

### 4.2. ノイズ整形

理想的な屋内環境のモデルにノイズを付与したモデルを入力点群とする。整形結果を図 2 に示す。また、整形点と理想面との平均誤差距離を表 1 に示す。提案手法において特徴量が 0 であれば平面部、0 でなければエッジ部とした。図 2 及び表 1 より、提案手法はエッジを残した滑らかな整形を行っており、従来手法と比較しても最も精度の高いノイズ整形を可能と

表 1. 整形点と理想面との誤差距離

手法	平均誤差 [m]	最大誤差 [m]
ノイズ付与	0.00465	0.0412
Bilateral	0.00436	1.00
MLS	0.00197	0.0291
APSS	0.00243	0.999
RIMLS	0.00250	0.477
提案手法	0.00115	0.0399

していることが確認できる。

## 5. むすび

LiDAR で取得した点群に対する特徴抽出手法、ノイズ整形手法を提案した。特徴抽出では近傍範囲を一つだけ用いた詳細なエッジ抽出を可能とし、ノイズ整形ではエッジを残した滑らかな整形を可能とした。

## 参考文献

- [1] Y.Ioannou, B.Taati, R.Hrrap, M.Green, "Difference of Normals as a Multi-scale Operator in Unorganized Point Clouds," 2012 Second International Conference on 3D Imaging, Modeling, Processing, Visualization and Transmission, pp.501-508, Oct. 2012.
- [2] 早田, 岩田, "3 次元点群からのマルチスケール特徴抽出法に関する検討," 情報処理学会オーディオビジュアル複合処理研究会報告 (AVM), Vol.2015-AVM-89, No.7, pp.1-6, Aug. 2015.
- [3] M.Pauly, R.Keiser, M.Gross, "Multi-scale Feature Extraction on Point-Samples Surfaces," Computer graphics forum, Vol.22, No.3, pp.281-289, Nov. 2003.
- [4] D.Levin, "Mesh-Independent Surface Interpolation," Geometric Modeling for Scientific Visualization, pp.37-49, Jan. 2003.
- [5] G.Guennebaud, M.Gross, "Algebraic point set surfaces," SIGGRAPH '07: ACM SIGGRAPH 2007 papers, Vol.26, No.3, July 2007.
- [6] A.C.Oztireli, G.Guennebaud, M.Gross, "Feature preserving point set surfaces based on nonlinear kernel regression," Computer Graphics Forum, Vol.28, No.2, pp.493-501, Apr. 2009.
- [7] J.Digne, Garlo de Franchis, "The Bilateral Filter for Point Clouds," Image Processing On Line, Vol.7, pp.278-287, Oct. 2017.

2019 年度

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

形状の特徴を考慮した点群のノイズ整形

Noise Shaping of Point Cloud Considering Shape Features

赤塚 紘輝

(5118F001-8)

提出日：2020.01.29

指導教員：渡辺 裕 印

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	序論	1
1.1	研究背景	1
1.2	本研究の目的	1
1.3	従来研究	2
1.3.1	特徴抽出	2
1.3.2	ノイズ整形	3
1.4	本論文の構成	3
第2章	関連技術	4
2.1	まえがき	4
2.2	主成分分析	4
2.3	判定分析法	6
2.4	コサイン類似度	7
2.5	むすび	7
第3章	ノイズ特性	8
3.1	まえがき	8
3.2	点群におけるノイズ特性の考慮	8
3.3	LiDAR	8
3.4	LiDAR で計測された点群におけるノイズ特性	9
3.4.1	実験	9
3.4.2	結果及び考察	11
3.4.3	まとめ	11
3.5	むすび	12
第4章	提案手法	13
4.1	まえがき	13
4.2	特徴抽出	13
4.2.1	特徴抽出手法の概要	13
4.2.2	特徴抽出手法	13
4.2.3	LiDAR で計測された点群における自動閾値導出	15
4.2.4	エッジ判定	15
4.3	ノイズ整形	16
4.3.1	ノイズ整形手法概要	16
4.3.2	平面部処理	16
4.3.3	エッジ部処理	17

4.3.4	ノイズ整形点の尤もらしさ.....	18
4.4	むすび.....	19
第5章	評価実験、結果及び考察.....	20
5.1	まえがき.....	20
5.2	実験環境.....	20
5.3	実験に使用するモデル.....	20
5.4	特徴抽出実験.....	23
5.4.1	実験概要.....	23
5.4.1.1	特徴抽出手法.....	23
5.4.1.2	自動閾値導出.....	24
5.4.1.3	エッジ判定.....	25
5.4.2	実験結果及び考察.....	26
5.4.2.1	特徴抽出手法の実験結果及び考察.....	26
5.4.2.2	自動閾値導出の実験結果及び考察.....	30
5.4.2.3	エッジ判定の実験結果及び考察.....	33
5.5	ノイズ整形実験.....	37
5.5.1	実験概要.....	37
5.5.2	実験結果及び考察.....	37
5.6	むすび.....	43
第6章	結論と今後の課題.....	44
6.1	結論.....	44
6.2	今後の課題.....	44
	謝辞.....	45
	参考文献.....	46
	図一覧.....	47
	表一覧.....	48
	研究業績.....	49
	受賞.....	50

# 第1章 序論

## 1.1 研究背景

近年、ロボット掃除機や自動運転車など様々な機械の自動化が進められている。ロボット掃除機では家具や壁面を避けるよう自動走行し、自動で床面の掃除を行う。自動運転車では現在、人間が操作しなくても一定の車間距離を維持したり、道路の白線を検知してふらつきを防いだり、衝突をブザーや減速で防いだりする機能が備えられている[1]。自動走行や自動運転では、カメラやセンサで得られた情報をもとに人間、遮断物の検知や距離計測などを行っている。

機械の自動走行、自動運転を実現するために用いられるセンサの一つとして LiDAR が挙げられる。LiDAR はレーザーを周囲に照射することで周囲の 3 次元構造を点群として取得する。点群を取得することでカメラ画像だけでは処理が難しい周囲の遮断物体検出や距離計測を容易に行うことができる。自動走行だけでなく、歴史的建造物の形状保存、測量や地図作成などにも活用できるため、点群を用いた研究が広く行われている。点群を用いた研究の一つとしてノイズ整形が挙げられる。LiDAR では容易に点群を取得することができるが、取得された点群には必ずノイズが含まれているという問題点がある。ノイズが含まれている状態では点群同士の位置合わせや、物体検出、セグメンテーションなどの精度に影響を及ぼし、十分な処理精度が得られない。そのためノイズ整形は点群を扱う上で重要な研究であると考えられる。

本論文では、まず LiDAR によって得られた点群のノイズ特性について調査する。得られたノイズ特性をもとに特徴抽出を行い、点群特徴を考慮することで点群ノイズ整形を行う。

以上の手法を行うとともに、実験により本手法の評価を行う。

## 1.2 本研究の目的

LiDAR を用いることで、自動走行や自動運転を可能とするだけでなく、周囲環境の 3 次元地図を作成することができる。これをドローンと組み合わせることで、例えば自然災害により人間や自動車が進入できない場合に内部へ自動飛行で侵入し、被害状況の把握や避難経路設定など容易に行うことができ、迅速な対応が可能となる。しかし、点群だけでは疎のデータであるため全貌を把握することは難しいという問題点がある。これに対し、点群データとカメラ画像を組み合わせることでより理想的な 3 次元地図を作成することが可能であると考えられる。ノイズを含む点群データとカメラ画像を組み合わせるために、点群ノイズ整形が必要である。

また、点群のより正確な3次元構造を再現することで、自動走行や環境地図作成を行うだけでなく、点群同士の位置合わせや物体検出、セグメンテーションなどの精度向上が可能であると考えられる。

現在、様々なノイズ整形手法が提案されているがどの手法も LiDAR で取得された点群に対する手法は少なく、ノイズ特性も考慮していない。したがって本論文では LiDAR で取得された点群のノイズ特性を考慮することでより精度の高いノイズ整形手法を提案する。

## 1.3 従来研究

### 1.3.1 特徴抽出

点群における特徴抽出とは、エッジやエッジ付近などの形状を特徴として数値的に評価する手法である。ここでエッジとは3次元形状の角の部分を目指す。局所点群の形状は共分散行列から得られる固有値により評価できる[2]。一般的に特徴抽出は局所点群から法線ベクトルや曲率を推定し、得られた値を用いて行われる。ここで曲率とは曲面の曲がり具合を示す指標である。

法線ベクトルを用いた手法では、注目点における大小二つの近傍範囲で主成分分析を行い、法線ベクトルを求め、得られた二つの法線ベクトルの差分を特徴量とする **Difference of Normals (DoN)**[3] という手法が提案されている。また、外球、内球の近傍範囲の取り方を、重なる部分がなくなるように DoN の外球から内球との重複部分を除去し、外球を中空球状にした **Donuts DoN (DDoN)**[4] や重複部と差分部を DoN とは反転させた **Ring DoN (RDoN)**[4] という手法がある。これらの手法はエッジ周辺に特徴を示す。

近似曲率を用いた手法では DoN, DDoN, RDoN の近傍範囲の取り方を使った **Difference of Curvatures (DoC)**[4], **Donuts DoC (DDoC)**[4], **Ring DoC (RDoC)**[4] が提案されている。DoC では DoN と同様にエッジ周辺に特徴を示すのに対し、DDoC や RDoN ではエッジそのものに特徴を示す。その他にも、より複数の近傍範囲で主成分分析を行い、近似曲率を求め、得られた近似曲率が閾値以上である割合を特徴量とする **マルチスケール特徴 (MS 特徴)**[5] という手法が提案されている。ノイズに対して頑健にエッジの特徴を示すことが可能であるが、多数の近傍範囲を用いるため処理速度が遅い。

このように特徴抽出手法は様々提案されているが、いずれの手法においても近傍範囲を複数用いるため、最適な近傍範囲の設定が困難である。

### 1.3.2 ノイズ整形

点群におけるノイズとは各点の位置が理想的な位置とは外れていることを指す。ノイズ整形とはこのノイズを正しい位置に整形したり、ノイズを除去したりすることである。ノイズ整形手法は主に外れ値除去と平滑化の2種類に分類される。

外れ値除去では一般的に平面や球体などのモデルで点群を近似し、そのモデル表面から各点の距離を計算し、距離の長い点はノイズとして削除するという手法[6][7]である。単純なモデルで近似しているため、複雑な形状を持つ点群では近似するのが困難であり、詳細な形状が失われる。

平滑化では主に移動最小二乗法 (以下, MLS) [8]が用いられている。MLS では滑らかな曲面を点群に合わせ、各点をその曲面に投影することで滑らかな整形を可能とする手法である。Guennebaud らはこのMLS をもとに球面フィッティングノイズ除去法 (APSS) [9]を提案している。この手法では低サンプリングレート及び高曲率下での精度を向上させている。また、Oztireli らはMLS と局所カーネル回帰に基づいた平滑化手法 (RIMLS)[10] を提案している。しかし、手法はいずれも外れ値に敏感であり、過度な平滑化をもたらす。MLS を用いない手法としてはBilateral Filter[11]が挙げられる。これは画像における2次元のBilateral Filter を3次元に拡張したものである。注目点と近傍点の距離や局所回帰平面との距離による重み付けを行っている。複数回フィルタをかけることでより滑らかな平滑化を可能としているが、過度な平滑化をもたらす。

## 1.4 本論文の構成

本論文の構成を以下に示す。

第1章は本章であり、本研究の背景や目的、従来研究について述べる。

第2章では関連技術について述べる。

第3章では本研究で用いるLiDAR機器の特性について述べる。

第4章では本論文で提案する手法について述べる。

第5章では提案手法の実験及び結果、考察について述べる。

第6章では本論文の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、本論文で用いる関連技術について述べる。

### 2.2 主成分分析

主成分分析とは、入力データの分散が最も大きくなるような射影軸を調べる手法である。

データ列  $\mathbf{A} = [\mathbf{a}_1 \ \cdots \ \mathbf{a}_n]^T$  が与えられたとする。ここで  $\mathbf{a}_i = [a_{i1} \ \cdots \ a_{im}]^T$  である。データの重心を  $\bar{\mathbf{a}} = [\bar{a}_1 \ \cdots \ \bar{a}_m]^T$  とし、重心からの差分で表したデータ列を  $\mathbf{A}' = [\mathbf{a}_1 - \bar{\mathbf{a}} \ \cdots \ \mathbf{a}_n - \bar{\mathbf{a}}]^T$  と定義する。

ところでデータの重心を通る任意の軸の基底ベクトルを  $\mathbf{e} = [e_1 \ \cdots \ e_m]^T$  とすると、その軸に射影したときのデータの分散は

$$\begin{aligned} \text{Var} &= \frac{\{(\mathbf{a}_1 - \bar{\mathbf{a}}) \cdot \mathbf{e}\}^2 + \cdots + \{(\mathbf{a}_n - \bar{\mathbf{a}}) \cdot \mathbf{e}\}^2}{n} \\ &= \frac{1}{n} [(\mathbf{a}_1 - \bar{\mathbf{a}}) \cdot \mathbf{e} \ \cdots \ (\mathbf{a}_n - \bar{\mathbf{a}}) \cdot \mathbf{e}] \begin{bmatrix} (\mathbf{a}_1 - \bar{\mathbf{a}}) \cdot \mathbf{e} \\ \vdots \\ (\mathbf{a}_n - \bar{\mathbf{a}}) \cdot \mathbf{e} \end{bmatrix} \\ &= \frac{1}{n} (\mathbf{A}'\mathbf{e})^T \mathbf{A}'\mathbf{e} \\ &= \mathbf{e}^T \frac{1}{n} \mathbf{A}'^T \mathbf{A}' \mathbf{e} \end{aligned} \tag{2.1}$$

と表せる。ここで

$$\mathbf{S} = \frac{1}{n} \mathbf{A}'^T \mathbf{A}' \tag{2.2}$$

は与えられたデータの分散共分散行列となっている。

主成分分析は式 2.1 の分散が最大となるような  $\mathbf{e}$  を求めることである。したがってラグランジェの未定乗数法を用いて、 $\mathbf{e}$  のノルムが 1 であるという制約の下、

$$L = \mathbf{e}^T \mathbf{S} \mathbf{e} - \lambda(\mathbf{e}^T \mathbf{e} - 1) \quad (2.3)$$

を導出できる. これを  $\mathbf{e}$  で偏微分することで

$$\frac{\partial L}{\partial \mathbf{e}} = 2\mathbf{S}\mathbf{e} - 2\lambda\mathbf{e} = \mathbf{0} \quad (2.4)$$

$$\mathbf{S}\mathbf{e} = \lambda\mathbf{e}$$

が得られる. 式 2.4 より, 主成分分析は与えられたデータの分散共分散行列の固有値問題に帰着することがわかる. 固有値問題を解くことで得られた固有ベクトルが主成分ベクトルとなる.

最大の分散をとる軸を第 1 主成分, それに直交して次に最大な分散をとる軸を第 2 主成分というように主成分が取得できる. 主成分を取得することでデータが持つ情報の損失を最小限にその軸へ射影することが可能となるため, 低次元空間への次元圧縮手法として多く用いられている.

点群においては通常平面近似手法として用いられる. 図 2.1 のように 3 つの主成分が取得でき, 第 1 主成分と第 2 主成分が近似平面の基底ベクトル, 第 3 主成分ベクトルが近似平面の法線ベクトルに相当する.

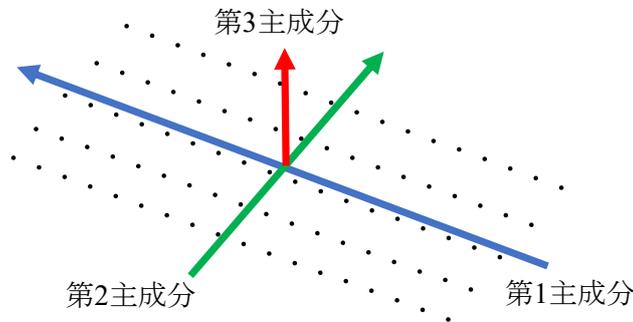


図 2.1 点群における主成分分析

主成分分析を用いて曲率を近似で求めることができる[12]. 曲率とは曲面の曲がり具合を示す値である. 第 1 主成分ベクトル, 第 2 主成分ベクトル, 第 3 主成分ベクトルに対応する固有値を  $\lambda_1$ ,  $\lambda_2$ ,  $\lambda_3$  とすると,

$$Curvature = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (2.5)$$

と近似曲率を表せる.

### 2.3 判定分析法

判定分析法[13]とはデータに対して分離度が最大となるような閾値を求め, 二つのクラスに分類する手法の一つである. 分離度は二つのクラスのクラス間分散とクラス内分散の比によって求められる. 判定分析法は画像の二値化でよく用いられる.

任意の範囲の値を持つデータ群が与えられたとする. このデータを二つのクラス, クラス 1 とクラス 2 に分類することを考える. 値  $k$  で二つにクラスに分類したときのクラス 1 のデータ数, 平均, 分散を  $\omega_1(k)$ ,  $m_1(k)$ ,  $\sigma_1^2(k)$  とし, クラス 2 のデータ数, 平均, 分散を  $\omega_2(k)$ ,  $m_2(k)$ ,  $\sigma_2^2(k)$  とする. これらを用いてクラス内分散は

$$\sigma_W^2(k) = \frac{\omega_1(k)\sigma_1^2(k) + \omega_2(k)\sigma_2^2(k)}{\omega_1(k) + \omega_2(k)} \quad (2.6)$$

と表せ, クラス間分散は

$$\sigma_B^2(k) = \frac{\omega_1(k)\omega_2(k)\{m_1(k) - m_2(k)\}^2}{\{\omega_1(k) + \omega_2(k)\}^2} \quad (2.7)$$

と表せる. ここで分離度は

$$\eta(k) = \frac{\sigma_B^2(k)}{\sigma_W^2(k)} \quad (2.8)$$

で求められる. この分離度が最大となる  $k$  がデータを二値化する最適な閾値となる.

ここでデータ全体の分散は

$$\sigma_T^2(k) = \sigma_W^2(k) + \sigma_B^2(k) \quad (2.9)$$

であることから分離度は

$$\eta(k) = \frac{\sigma_B^2(k)}{\sigma_T^2(k) - \sigma_B^2(k)} \quad (2.10)$$

と表せる。したがって、分離度が最大となる  $k$  を求めるためにはクラス間分散が最大となる  $k$  を求めればよいことがわかる。

## 2.4 コサイン類似度

コサイン類似度とは、ベクトルの内積を用いてデータの類似度を算出する手法であり、ベクトル同士の同方向具合を表す指標である。ベクトル  $\mathbf{s}$  及び  $\mathbf{t}$  が与えられたとすると、コサイン類似度は

$$\text{sim}(\mathbf{s}, \mathbf{t}) = \frac{\mathbf{s} \cdot \mathbf{t}}{\|\mathbf{s}\|_2 \|\mathbf{t}\|_2} \quad (2.11)$$

で表せる。取りうる値は  $-1 \leq \text{sim}(\mathbf{s}, \mathbf{t}) \leq 1$  である。数値が大きくなるほど類似度が高いことを表す。

## 2.5 むすび

本章では、本論文で用いる関連技術について述べた。

## 第3章 ノイズ特性

### 3.1 まえがき

本章では本研究で用いる LiDAR 機器の特性について述べる。

### 3.2 点群におけるノイズ特性の考慮

点群のノイズ特性を考慮せずにノイズ整形を行うことで、実際の計測点群に対して十分な精度が得られない可能性がある。ノイズが含まれるデータを扱う場合、ノイズ特性を考慮する必要があると考えられる。しかし、点群におけるノイズ特性について言及している論文は少ない。通常、モデルとして点群にノイズを付与する場合、理想点群に平均が 0 のガウシアンノイズを付与するが、実際にノイズが正規分布に従うかは定かではない。したがって、本論文では点群におけるノイズは正規分布に従うという仮定の下、予備実験として本実験で用いる LiDAR 機器のノイズ特性を確かめる。

### 3.3 LiDAR

LiDAR とは Light Detection and Ranging (光による検知と測距) の略語である。レーザーを周囲に照射し、物体に反射して戻ってくるまでの時間を測定することによって対象物の方向及び対象物までの距離を測定する。通常 XYZ などの直交座標データを持つ点群として得られる。また反射強度を返す機能を持つ機器もあり、対象物の表面性質も推定可能である。

本研究では図 3.1 の VLP-16 という LiDAR を用いる。



図 3.1 VLP-16

VLP-16 は Velodyne LiDAR 社製 LiDAR である。水平角 360 度全方位，仰角 30 度の範囲が測定可能であり，寸法は高さ 72.7mm × 直径 103.3mm ，重量は約 830g である。図 3.2 のように仰角-15 度から 15 度まで 2 度ずつ角度のついた 16 本のレーザーを持ち，レーザー波長は 903nm である。それらのレーザーを照射しながら 360 度回転することで計測している。測距可能範囲は 0.5-100m，回転速度は 600rpm，測定誤差は 25m で  $1\sigma = \pm 3\text{cm}$  である。

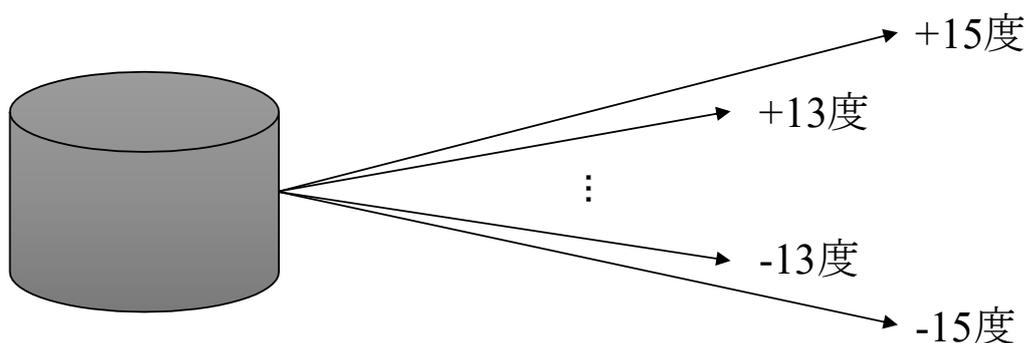


図 3.2 VLP-16 のレーザー照射

16 本のレーザーは同時に照射されるのではなく 1 本ずつ照射されており，その間隔は  $2.304\mu\text{s}$  である。16 本のレーザー照射後， $18.43\mu\text{s}$  の充電時間が必要となる。つまり，レーザーの照射後，同じレーザーが次の照射までに要する時間は  $2.304 \times 16 + 18.43 = 55.29\mu\text{s}$  となる。回転速度が 600rpm であることから，隣り合う点どうしの角度は約 0.2 度となる。

水平方向 0.2 度ずつ 360 度，仰角方向 2 度ずつ-15 度から 15 度の点が取得できるため，1 回転で約 30000 点，1 秒間で約 300000 点の点群が取得可能である。

### 3.4 LiDAR で計測された点群におけるノイズ特性

#### 3.4.1 実験

LiDAR の内部座標と実空間座標を合わせ，図 3.3 のように平面物体を配置して計測する。平面物体に反射して得られた計測点群の理想平面との誤差距離を算出する。

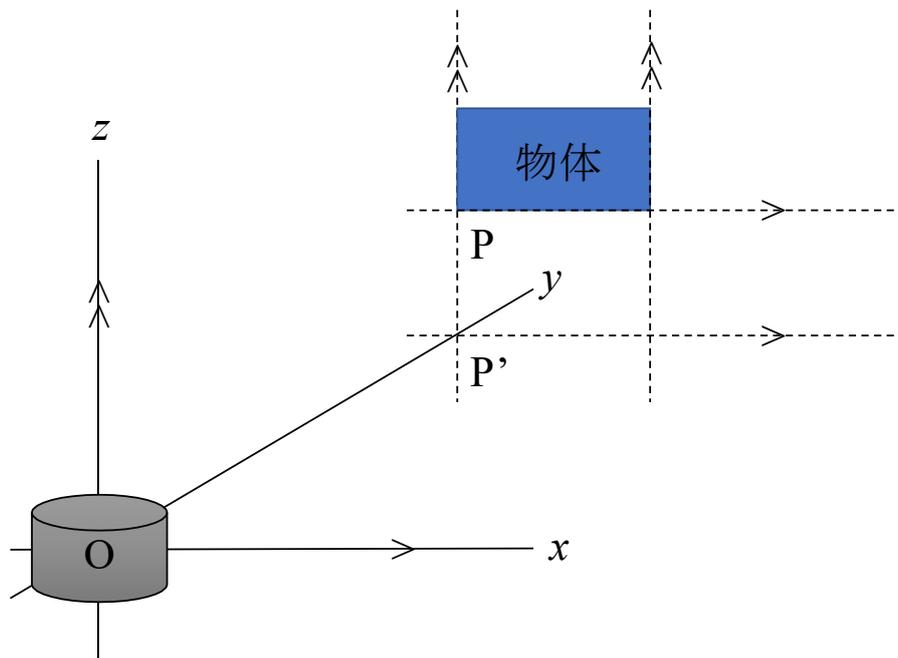


図 3.3 ノイズ特性実験環境図

ここで  $OP'=332.45\text{cm}$ ,  $PP'=70.90\text{cm}$  である。また、算出誤差距離は最短距離ではなく、図 3.4 のように LiDAR からの角度が等しい点との距離を用いる。これは誤差要因が水平角や仰角の角度によるものではなく、反射時間によるものと考えられるためである。

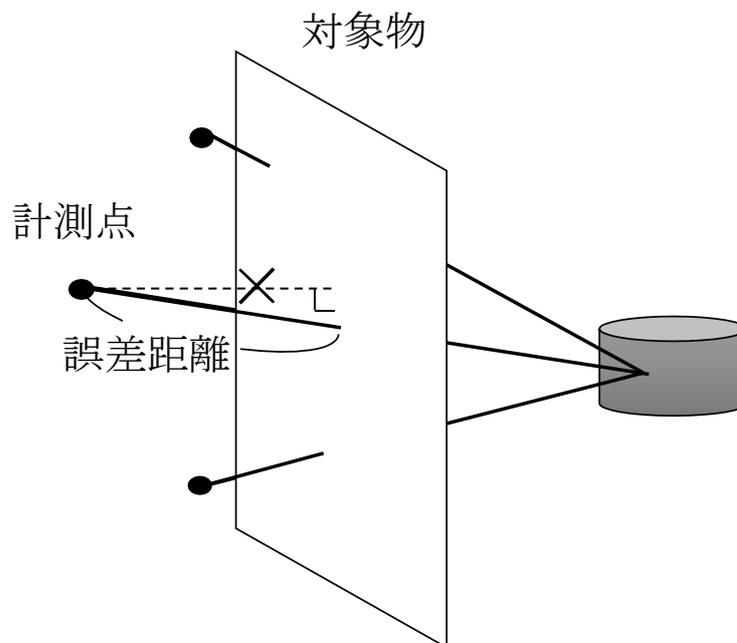


図 3.4 算出する誤差距離

### 3.4.2 結果及び考察

3.4.1 節で述べた実験を行い，誤差の 0.3cm 区切りの出現回数をヒストグラムで表した結果を図 3.5 に示す．

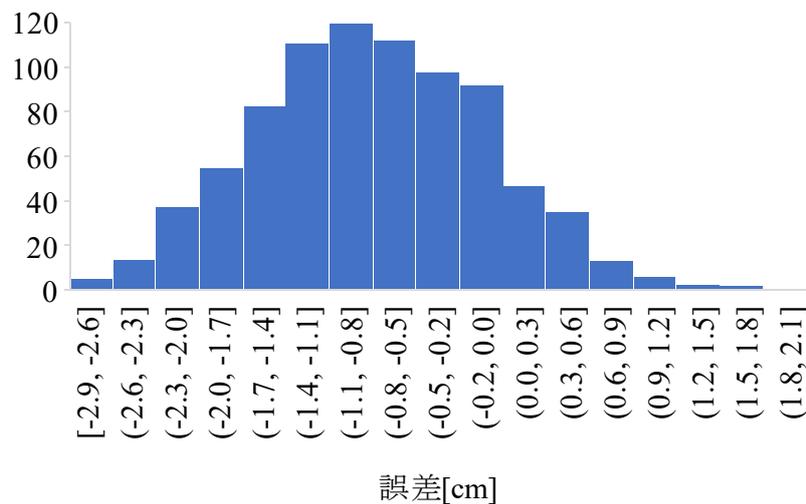


図 3.5 計測されたデータの誤差分布

図 3.5 より計測された点のノイズは正規分布に従うと推測される．正規分布と仮定することで平均-0.82cm，標準偏差 0.78cm と算出することができる．

実験環境はメジャーを用いて計測しており，理想値の誤差は少なからず生じている．平均が 0cm でなかったのはこれが原因の一つであると考えられるため，本論文では LiDAR で生じるノイズは平均が 0 の正規分布に従うとする．

本実験では 3.3245m の距離で標準偏差 0.78cm のガウシアンノイズが確認できた．仕様によると 25m で  $1\sigma = \pm 3\text{cm}$  のノイズが生じる．ノイズの標準偏差が距離に対して線形であると仮定すると，計測機器の位置を原点として，各点の距離  $x$  で生じるノイズの標準偏差  $\sigma$  は式 3.1 で表せる．

$$\sigma = \frac{0.102x + 0.45}{100} \quad (3.1)$$

### 3.4.3 まとめ

LiDAR で計測された点群におけるノイズ特性を実験により調べることで，ノイズは距離における正規分布に従うと推測できた．また，その標準偏差は計算式により算出できる．

本論文ではこの結果を LiDAR のノイズ特性として用いる．

### 3.5 むすび

本章では本研究で用いる LiDAR 機器のノイズ特性について述べた.

## 第4章 提案手法

### 4.1 まえがき

本章では LiDAR で取得された点群に対するノイズ整形手法について述べる。取得点群に対して点群形状を推定するための特徴抽出手法を提案し、得られた特徴量をもとにノイズ整形手法を提案する。

### 4.2 特徴抽出

#### 4.2.1 特徴抽出手法の概要

従来手法では複数の近傍範囲に対して主成分分析を行い、得られた法線ベクトルや近似曲率をもとに特徴抽出を行っている。複数の近傍範囲を用いることで頑健な特徴抽出が可能だが、近傍範囲値の設定が困難であるという問題が生じる。LiDAR で取得された点群においては3.4節で述べたようにノイズ量は大きくないと考えられる。したがって、一つの近傍範囲のみで行う特徴抽出手法を提案する。さらに得られた特徴量を二値化することで各点がエッジであるか判定する手法も提案する。

#### 4.2.2 特徴抽出手法

点群各点の近傍範囲において主成分分析を行い、得られた法線から平面方程式を算出し、近傍範囲内の点群が算出された平面上に存在しない割合を特徴量とする。点群が平面上に存在しない割合を特徴量としているのは点群形状がエッジであればあるほど特徴を示すようにするためである。特徴抽出手法の概念図を図4.1に示す。この図の場合、平面上に存在する点群が多いため特徴量は低い値となる。

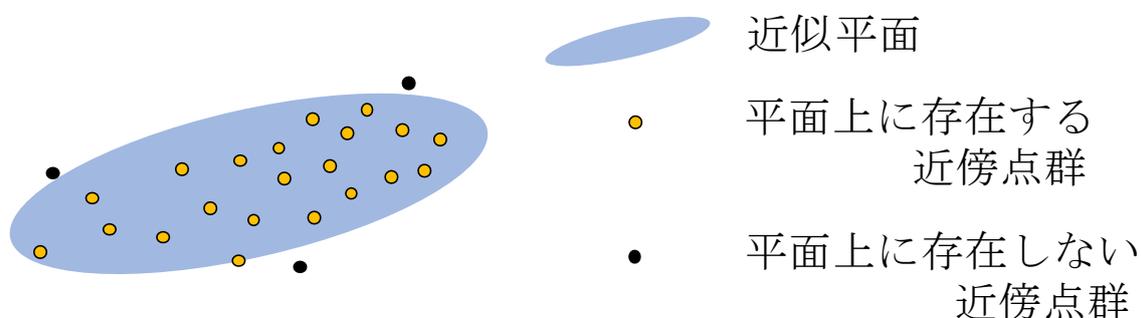


図 4.1 特徴抽出手法概念図

M 個の点群  $\mathbf{P} = \{\mathbf{p}_i\}_{i=1}^M$ ,  $\mathbf{p}_i \in \mathbb{R}^3$  が与えられたとする. それぞれの点に対する近傍点群を  $\mathcal{N}(\mathbf{p}_i) = \{\mathbf{q}_{ij}\}_{j=1}^{|\mathcal{N}(\mathbf{p}_i)|}$ ,  $\mathbf{q}_{ij} \in \mathbf{P}$  と定義する. ここで  $|\mathcal{N}(\mathbf{p}_i)|$  は近傍点群数を表す. 近傍点群に主成分分析を行うことで法線ベクトル  $\mathbf{n}_i$  が得られる. この法線ベクトルはすでに正規化されているとする. 近傍点群の重心を  $\mathbf{g}_i$  とすると, 各点の近傍点群における近似平面は

$$\mathbf{n}_i^T \begin{pmatrix} x \\ y \\ z \end{pmatrix} - \mathbf{g}_i = 0 \quad (4.1)$$

と表せる. この近似平面上に点群が存在しない割合を特徴量とするが, ノイズが付与されている場合, 点群が平面上に存在する確率は極めて低いと考えられる. そのため許容誤差範囲を設定する.

ある点  $\mathbf{p}_0 = [x_0 \ y_0 \ z_0]^T$  が与えられ, その点と 4.1 式で表せる平面との距離を考える. その距離  $D_0$  は

$$D_0 = \frac{|\mathbf{n}_i^T(\mathbf{p}_0 - \mathbf{g}_i)|}{\|\mathbf{n}_i\|_2} \quad (4.2)$$

と表せる. ここで法線ベクトルは正規化されているので分母は考慮しなくてよい. よって近傍点群と近似平面との距離  $D$  は

$$D = |\mathbf{n}_i^T(\mathbf{q}_{ij} - \mathbf{g}_i)| \quad (4.3)$$

となる.

したがって許容誤差範囲  $\tau$  を用いて各点  $\mathbf{p}_i$  の特徴量  $\omega_i$  は以下のように表せる.

$$\omega_i = \frac{1}{|\mathcal{N}(\mathbf{p}_i)|} \sum_{j=1}^{|\mathcal{N}(\mathbf{p}_i)|} \Omega_{i,j}, \quad \Omega_{i,j} = \begin{cases} 1 & |\mathbf{n}_i^T(\mathbf{q}_{ij} - \mathbf{g}_i)| \geq \tau \\ 0 & \text{otherwise} \end{cases} \quad (4.4)$$

特徴量は最小が 0, 最大が 1 をとる値となり, エッジであれば 1 に近く, そうでなければ 0 に近い値となる.

### 4.2.3 LiDAR で計測された点群における自動閾値導出

3.4 節で述べたように LiDAR で生じるノイズは計測距離に対して正規分布に従う。正規分布では図 4.2 のように平均を  $\mu$ 、標準偏差を  $\sigma$  とするとすべてのデータの 99.7% が  $\mu \pm 3\sigma$  以内に分布するという特徴をもつ。

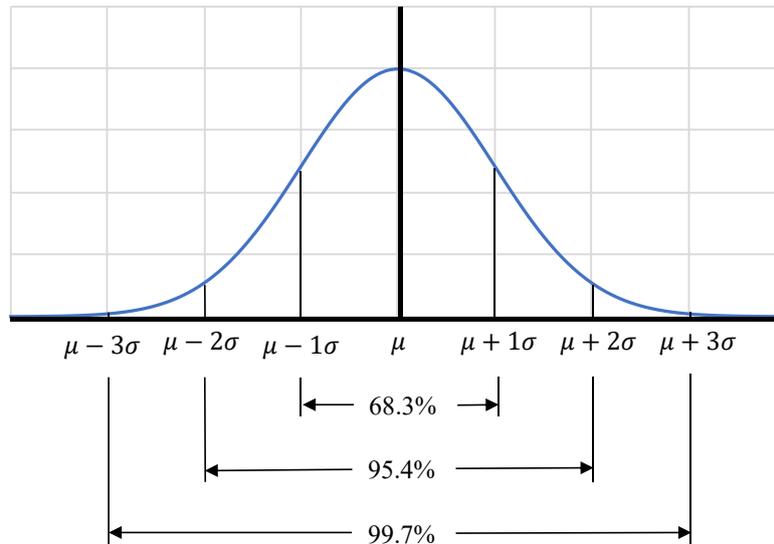


図 4.2 正規分布例

この特徴から LiDAR で取得された点群も理想位置から  $\mu \pm 3\sigma$  以内に存在する可能性が高いことがわかる。求めた近似平面が理想平面であると仮定すると、許容誤差範囲  $\tau$  は式 3.1 より

$$\begin{aligned}\tau &= 3\sigma \\ &= 3 \times \frac{0.102x + 0.45}{100}\end{aligned}\tag{4.5}$$

と算出可能となる。ここで  $x$  は点  $p_i$  と計測原点との距離である。この閾値を用いることでどの距離の点においても平面に属する点は特徴を示さず、エッジに近い点ほど特徴を大きく示す特徴抽出が可能となる。

### 4.2.4 エッジ判定

特徴抽出によって得られた特徴量をもとに各点がエッジに属する点であるか判定する。

特徴量のある小さな範囲ずつに分け、ヒストグラムを作成する。次に判定分析法を用いてこのヒストグラムを二つに分類する値  $k$  を求める。E をエッジに属する点の集合、F をエッジに属さない点の集合とすると

$$\begin{aligned} E &= \{\mathbf{p}_i \mid k < \omega_i \leq 1\} \\ F &= \{\mathbf{p}_i \mid 0 \leq \omega_i \leq k\} \end{aligned} \quad (4.6)$$

のように  $k$  を用いて各点のエッジ判定が可能となる。

### 4.3 ノイズ整形

#### 4.3.1 ノイズ整形手法概要

特徴抽出によって得られた各点の近傍点群重心、法線、特徴量を用いてノイズ整形を行う。エッジ判定により、各点がエッジに属する点かすでに分かっている。エッジに属する点群をエッジ部、属さない点群を平面部とよぶこととする。平面部では法線と近傍点群重心から近似平面がわかるため、その平面上に各点を移動させることでノイズ整形を行う。ここで平面部はエッジ部以外であるため、平面だけでなく曲面に属する点も存在するが、局所的には平面で近似できるため、整形可能であると考えられる。よって曲面も平面と同じ処理を行う。しかし、エッジ部では平面部と同じ処理を行うと、近傍点群の重心方向に移動するためエッジが過度に滑らかになってしまうと考えられる。したがって、平面部とエッジ部では異なる処理を行う。

#### 4.3.2 平面部処理

各点の法線、近傍点群重心から算出される平面方程式上に点を移動させることでノイズ整形を行う。3.4 節より LiDAR で計測された点群におけるノイズは計測距離に対して付与されることがわかっている。したがって各点を平面方程式上に移動させる際、点を最短距離方向に移動させるのではなく原点方向に移動させることで、ノイズ点群を理想位置に整形可能であると考えられる。

平面  $ax + by + cz + d = 0$  と原点から方向ベクトル  $\mathbf{v}$  の直線との交点は  $-\frac{d}{a\alpha + b\beta + c\gamma}\mathbf{v}$  で表せる。つまり、各点  $\mathbf{p}_i = [p_{ix} \ p_{iy} \ p_{iz}]^T$  の法線を  $\mathbf{n}_i = [n_{ix} \ n_{iy} \ n_{iz}]^T$ 、近傍点群重心を  $\mathbf{g}_i = [g_{ix} \ g_{iy} \ g_{iz}]^T$  とすると平面方程式は

$$\mathbf{n}_i^T \begin{pmatrix} x \\ y \\ z \end{pmatrix} - \mathbf{g}_i = 0$$

$$[n_{ix} \quad n_{iy} \quad n_{iz}] \begin{bmatrix} x - g_{ix} \\ y - g_{iy} \\ z - g_{iz} \end{bmatrix} = 0$$

$$n_{ix}x + n_{iy}y + n_{iz}z + (-n_{ix}g_{ix} - n_{iy}g_{iy} - n_{iz}g_{iz}) = 0 \quad (4.7)$$

となり，原点から方向ベクトル  $\mathbf{p}_i$  との交点は  $\frac{n_{ix}g_{ix}+n_{iy}g_{iy}+n_{iz}g_{iz}}{n_{ix}p_{ix}+n_{iy}p_{iy}+n_{iz}p_{iz}}\mathbf{p}_i$  と表すことができる。

したがって平面部に属する各点  $\mathbf{p}_i \in \mathbf{F}$  のノイズ整形後の点  $\hat{\mathbf{p}}_i$  は

$$\hat{\mathbf{p}}_i = \frac{\mathbf{n}_i^T \mathbf{g}_i}{\mathbf{n}_i^T \mathbf{p}_i} \mathbf{p}_i \quad (4.8)$$

と算出できる。

### 4.3.3 エッジ部処理

エッジ部は図 4.3 のように平面部に挟まれるように存在すると考えられる。つまり，エッジ部では平面部の平面方程式を用いて理想面を近似できる。したがってエッジ部処理では，注目点のもつ法線と類似度の高い法線をもち，特徴量が低い最近傍点を用いて算出される平面方程式上に移動させることでノイズ整形を行う。

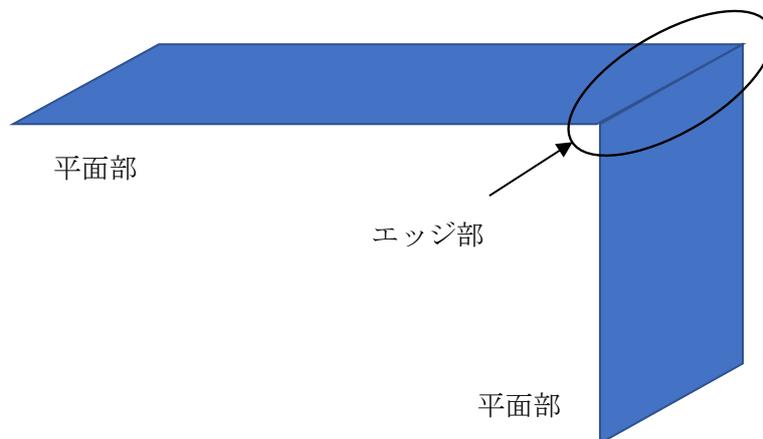


図 4.3 エッジ部周辺図

注目点  $\mathbf{p}_i$  と近傍点群  $\mathcal{N}(\mathbf{p}_i) = \{\mathbf{q}_{i,j}\}_{j=1}^{|\mathcal{N}(\mathbf{p}_i)|}$  があり，注目点は法線  $\mathbf{n}_i$ ，近傍点群重心  $\mathbf{g}_i$  をもち，各近傍点は法線ベクトル  $\mathbf{n}_{q_{i,j}}$ ，近傍点群重心  $\mathbf{g}_{q_{i,j}}$  をもつとする．注目点の法線とコサイン類似度の高い法線をもつ近傍点集合を考える．ここで法線ベクトルの向きが反対を向いているベクトルも存在することを考慮するとその近傍点集合は

$$\mathbf{Q}_{sim} = \{\mathbf{q}_{i,j} \mid \|sim(\mathbf{n}_i, \mathbf{n}_{q_{i,j}})\| > \varepsilon\} \quad (4.9)$$

と表現できる． $\varepsilon$  は注目点の法線と近傍点の法線の類似度の高さを調整する閾値である．この集合内で特徴量が一番小さい近傍点集合

$$\mathbf{Q}_{min} = \operatorname{argmin}_{\mathbf{q}_{i,j}}(\omega_i), \quad \mathbf{Q}_{min} \subset \mathbf{Q}_{sim} \quad (4.10)$$

を考える．この集合内で注目点との距離が一番近い点

$$\mathbf{q}_{near} = \operatorname{argmin}_{\mathbf{q}_{i,j}}(\|\mathbf{q}_{i,j} - \mathbf{p}_i\|_2), \quad \mathbf{q}_{near} \in \mathbf{Q}_{min} \quad (4.11)$$

を求める．この点のもつ法線ベクトル  $\mathbf{n}_{q_{near}}$  と近傍点群重心  $\mathbf{g}_{q_{near}}$  を用いて平面部と同様の処理を行う．したがって，エッジ部に属する各点  $\mathbf{p}_i \in \mathbf{E}$  のノイズ整形後の点  $\hat{\mathbf{p}}_i$  は

$$\hat{\mathbf{p}}_i = \frac{\mathbf{n}_{q_{near}}^T \mathbf{g}_{q_{near}}}{\mathbf{n}_{q_{near}}^T \mathbf{p}_i} \mathbf{p}_i \quad (4.12)$$

と算出できる．

#### 4.3.4 ノイズ整形点の尤もらしさ

4.3.2 節と 4.3.3 節で点群のノイズ整形手法について述べた．しかしながら，モデルによっては各点の近傍点群数が異なり，ある点において十分な近傍点を得られずに尤もらしい平面方程式を算出できない場合があると考えられる．したがって，ノイズ整形点が尤もらしい位置に整形されていない点を除去する．

4.2.3 節より，LiDAR で計測された点と本来整形されるべき点との最大距離は式 4.5 より小さい値になると考えられる．したがって，ノイズ整形前の点とノイズ整形後の点との距離を算出し，式 4.5 よりも大きい値であればその点を除去する．

#### 4.4 むすび

本章では特徴抽出及びノイズ整形の提案手法について述べた。

## 第5章 評価実験、結果及び考察

### 5.1 まえがき

本章では第4章で提案した手法の評価実験を行う。また、従来手法との比較を行い、考察する。

### 5.2 実験環境

実験を行った環境を表5.1に示す。

表 5.1 実験環境

OS	Windows 10 Home ver.1903
CPU	Intel Core i7-7700 3.60GHz
GPU	NVIDIA GeForce GTX 1080Ti

### 5.3 実験に使用するモデル

実験では単純な理想モデル、現実空間に近い理想モデル及び計測した現実空間モデルの三つのモデルを用いる。特徴抽出の実験では単純な理想モデル、計測した現実空間モデルを用い、ノイズ整形の実験では現実空間に近い理想モデル、計測した現実空間モデルを用いる。

一つ目の単純な理想モデルは1辺50cmの正方形3面から構成された点群である。このモデルに2種類のガウシアンノイズを付与する。一つ目はモデル各点の座標値それぞれに平均が0、標準偏差が1のガウシアンノイズを付与する。このノイズを一般ノイズとよぶこととする。二つ目はモデルが計測原点からy方向に+3m、z方向に-4mの位置に存在すると仮定し、平均が0、標準偏差が式3.1に従うようなガウシアンノイズを各点の距離に対して付与する。このノイズをLiDARノイズとよぶこととする。これらを図5.1に示す。

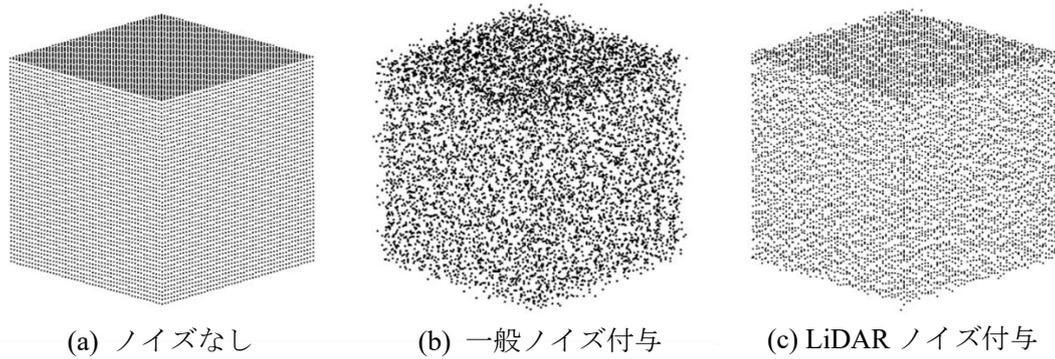


図 5.1 単純な理想モデル

二つ目の現実空間に近い理想モデルは実際に LiDAR で室内を計測したような点群である。壁面、床面、天井面を任意に設定し、仰角が $-15$ 度 $\sim +15$ 度で $2$ 度ずつ、水平角が $360$ 度で $0.2$ 度ずつレーザー照射が行われるという仮定のもとコンピュータ上で点群を作成する。このモデルを図 5.2 に示す。左が上からの図で右が斜め上からの図である。

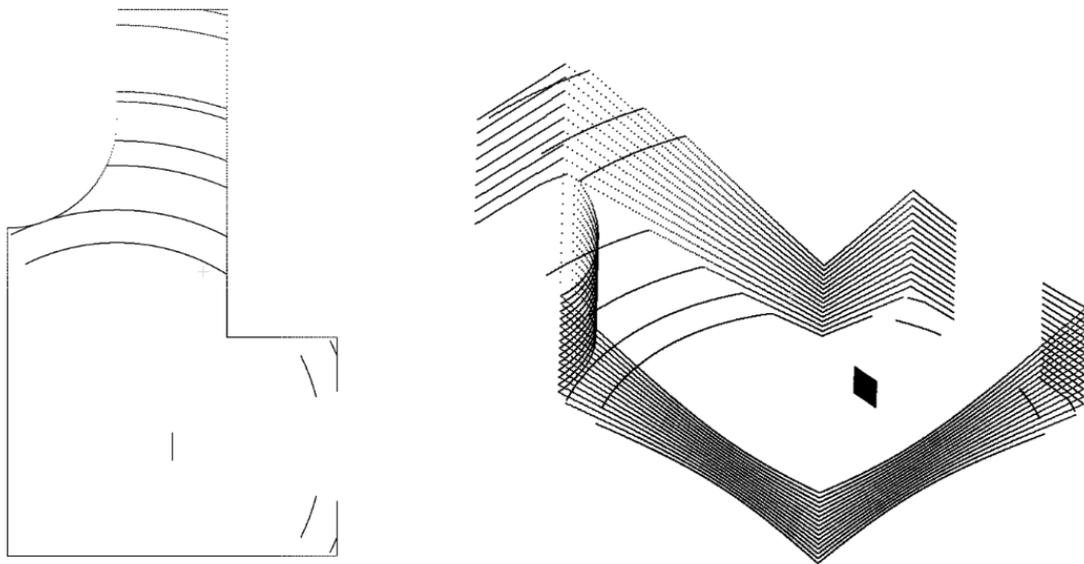


図 5.2 現実空間に近い理想モデル(ノイズ無し)

三つ目の計測した現実空間モデルは図 5.3 の場所で計測した点群である。



図 5.3 計測場所

この場所で計測された点群を図 5.4 に示す。

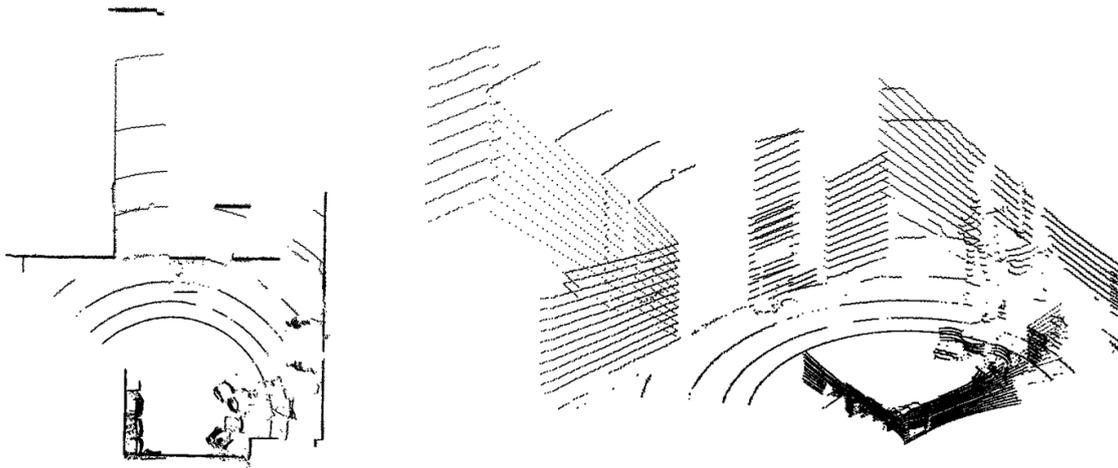


図 5.4 計測した現実空間モデル

従来手法及び提案手法をこれら三つのモデルに適用させることで提案手法の評価を行う。

今後、表 5.2 で示すように図 5.1 の (a)ノイズなしモデルを理想モデル 1-1, (b)一般ノイズ付与モデルを理想モデル 1-2, (c) LiDAR ノイズ付与モデルを理想モデル 1-3, 図 5.2 のモデルを理想モデル 2, 図 5.4 のモデルを計測モデルとよぶこととする。

表 5.2 モデル一覧

モデル名	モデルの説明
理想モデル 1-1	単純な理想モデル(ノイズ無し)
理想モデル 1-2	単純な理想モデル(一般ノイズ付与)
理想モデル 1-3	単純な理想モデル(LiDAR ノイズ付与)
理想モデル 2	現実空間に近い理想モデル
計測モデル	計測した現実空間モデル

## 5.4 特徴抽出実験

### 5.4.1 実験概要

#### 5.4.1.1 特徴抽出手法

4.2.2 節で提案した特徴抽出手法について有効性を確認する実験を行う。理想モデル 1-1 及び理想モデル 1-2 に対して従来手法, 提案手法を適用する。従来手法は DoN, DoC, DDoN, DDoC, RDoN, RDoC, MS 特徴を用いる。実験で使用する従来手法及び提案手法のパラメータを表 5.3 に示す。

表 5.3 特徴抽出実験で用いるパラメータ

手法	近傍範囲 1 [cm]	近傍範囲 2 [cm]	閾値
DoN	7.5	15.0	0.04
DoC			
DDoN			
DDoC			
RDoN			
RDoC			
MS 特徴	7.5	15.0	0.04
提案手法	7.5		1.5 / 3.0

MS 特徴では近傍範囲 1 から近傍範囲 2 へ 2.5cm ずつ近傍範囲を変化させる。提案手法の閾値は理想モデル 1-1 に対しては 1.5 に設定するが、理想モデル 1-2 に対してはノイズに対応するため 1.5 と 3.0 の 2 種類設定する。

#### 5.4.1.2 自動閾値導出

4.2.3 節で提案した自動閾値導出を行っても特徴抽出手法が有効か確かめる。理想モデル 1-3 及び計測モデルに対して特徴抽出の従来手法，提案手法を適用する。ここで提案手法の閾値設定は式 4.5 を用いて設定する。それ以外の近傍範囲などのパラメータについては理想モデル 1-3 においては表 5.3 と同様に設定する。計測モデルにおいては理想モデル 1-3 とはスケールが異なるため，近傍範囲など異なる値を設定する必要がある。

計測された点群は計測原点から近い場所では密に，遠い場所では疎になっている。計測点からの距離に関係なく近傍範囲を設定すると，計測点から遠い場所では近傍点数が少なく特徴抽出がうまく行えない可能性がある。したがって計測モデルにおいては計測点からの距離に関係なく近傍点群数がおおよそ等しくなるように近傍範囲を設定する。計測された点群では各点と最近傍点との角度差は水平角約 0.01 度，仰角 2 度である。そのため近傍範囲内の最遠傍点と注目点の角度差が 2 度より小さい場合，垂直方向の特徴を抽出することはできない。したがって近傍範囲は近傍範囲内の最遠傍点と注目点の角度差が 4 度になるように設定することとする。従来手法では近傍範囲が複数必要であるため，4 度と 8 度の角度差を用いることとする。角度差が 4 度の場合，近傍範囲は

$$r_s = 2 \times 0.035x \quad (5.1)$$

となり，8 度の場合は

$$r_l = 4 \times 0.035x \quad (5.2)$$

と表すことができる。ここで  $x$  は注目点の計測原点からの距離を表す。

理想モデル 1-3 での実験で用いるパラメータを表 5.4 に，計測モデルでの実験で用いるパラメータを表 5.5 に示す。

表 5.4 理想モデル 1-3 での自動閾値導出実験で用いるパラメータ

手法	近傍範囲 1 [cm]	近傍範囲 2 [cm]	閾値
DoN	7.5	15.0	/
DoC			
DDoN			
DDoC			
RDoN			
RDoC			
MS 特徴	7.5	15.0	0.04
提案手法	7.5	/	$3 \times \frac{0.102x + 0.45}{100}$

表 5.5 計測モデルでの自動閾値導出実験で用いるパラメータ

手法	近傍範囲 1 [cm]	近傍範囲 2 [cm]	閾値
DoN	$2 \times 0.035x$	$4 \times 0.035x$	/
DoC			
DDoN			
DDoC			
RDoN			
RDoC			
MS 特徴	$2 \times 0.035x$	$4 \times 0.035x$	0.04
提案手法	$2 \times 0.035x$	/	$3 \times \frac{0.102x + 0.45}{100}$

MS 特徴での近傍範囲の変化値は

$$r_{interval} = \frac{(r_l - r_s)}{4} \quad (5.3)$$

とする。近傍範囲を式 5.3 ずつ変化させて特徴抽出を行う。

#### 5.4.1.3 エッジ判定

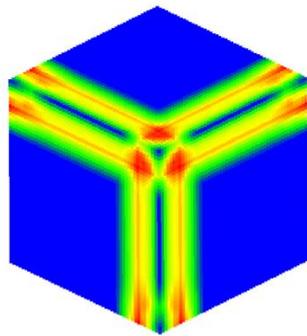
4.2.4 節で述べたエッジ判定により、提案した特徴抽出の有効性を確かめる実験を行う。理想モデル 1-3 及び計測モデルでの自動閾値導出実験で得られた特徴量をもとにエッジ判

定を行い，特徴抽出各手法の特徴抽出精度を比較する．理想モデル 1-3 は理想的なモデルであり，エッジの真値が明確なため，理想モデル 1-3 を用いてエッジ判定を数値的に評価する．

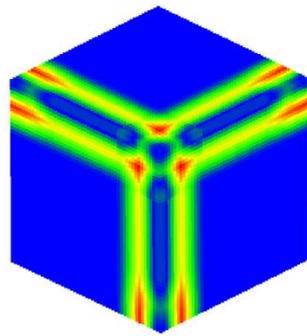
## 5.4.2 実験結果及び考察

### 5.4.2.1 特徴抽出手法の実験結果及び考察

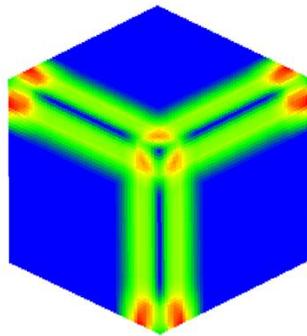
5.4.1.1 節で述べた実験を行う．理想モデル 1-1 及び理想モデル 1-2 において得られた特徴量結果を最小値が青，最大値が赤のヒートマップで図 5.5，図 5.6 に示す．また，点群 1 点あたりの処理時間を表 5.6 に示す．



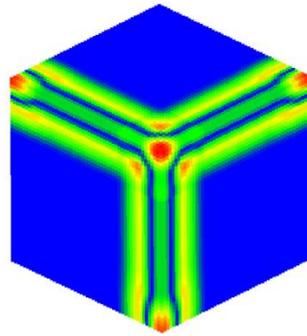
(a) DoN



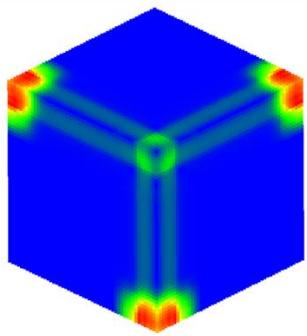
(b) DoC



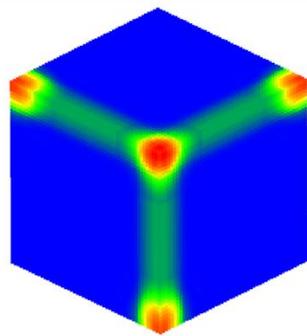
(c) DDoN



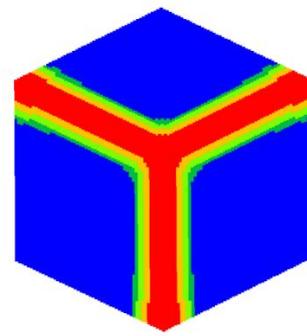
(d) DDoC



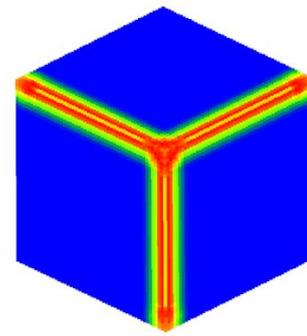
(e) RDoN



(f) RDoC



(g) MS 特徴



(h) 提案手法

図 5.5 理想モデル 1-1 における特徴量カラーマップ

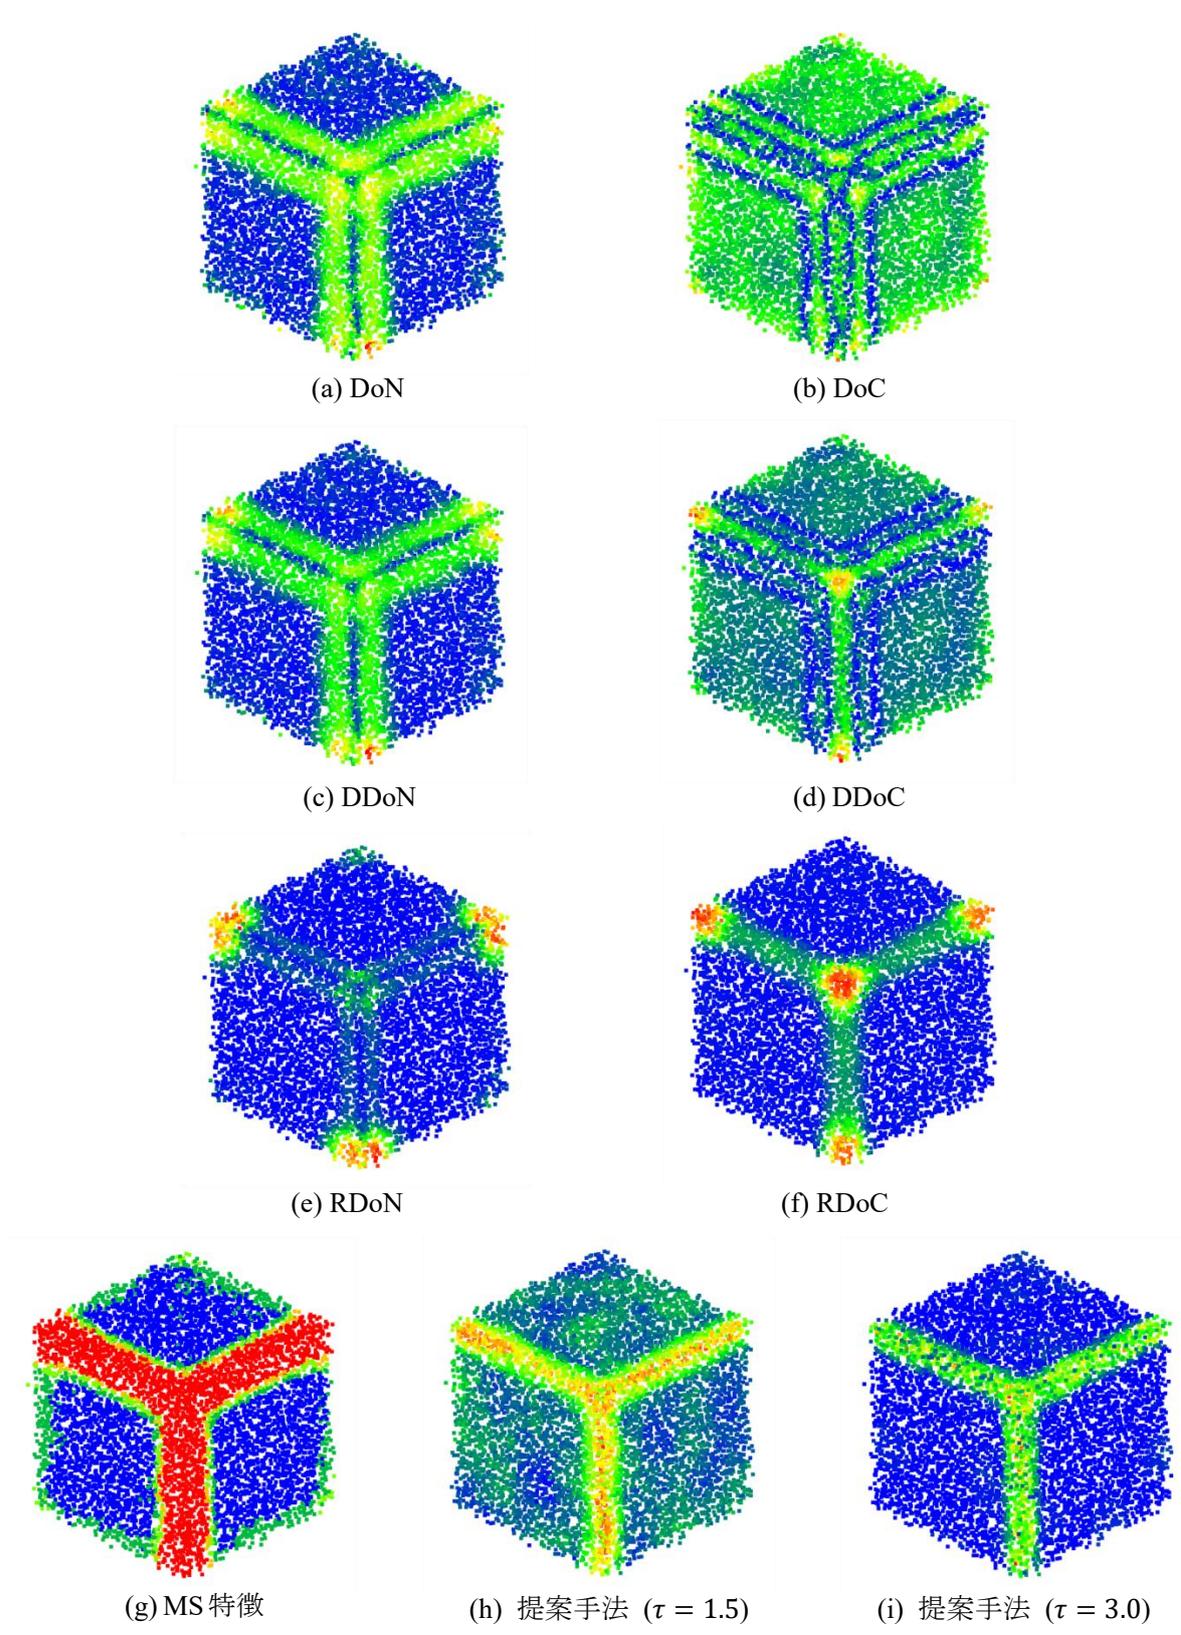


図 5.6 理想モデル 1-2 における特徴量カラーマップ

表 5.6 特徴抽出の点群 1 点あたりの処理時間

手法	理想モデル 1-1 [ms]	理想モデル 1-2 [ms]
DoN	0.555	0.546
DoC	0.511	0.501
DDoN	0.546	0.549
DDoC	0.517	0.530
RDoN	0.606	0.613
RDoC	0.610	0.594
MS 特徴	1.078	1.026
提案手法( $\tau = 1.5$ )	0.262	0.245
提案手法( $\tau = 3.0$ )	0.262	0.248

図 5.5 において DoN, DoC, DDoN ではエッジ周辺に特徴を示している。DDoC ではエッジ及びエッジ周辺に特徴を示している。RDoN ではオクルージョンのあるエッジに強く特徴を示している。RDoC ではエッジに特徴を示し、特にエッジの頂点部分に強い特徴を示している。これらに対し、MS 特徴と提案手法ではエッジに特徴を示しているのがわかる。提案手法では MS 特徴よりも細部に特徴を抽出ことに成功している。提案手法においてエッジよりエッジ周辺に最も特徴を示しているが、これは平面方程式が近傍点群の重心位置をもとに算出されており、エッジの少しずれた点のほうが平面方程式上に近傍点群が存在しないからである。平面方程式を注目点位置をもとに算出することでこの問題を解決できるが、ノイズに弱い手法になると考えられる。

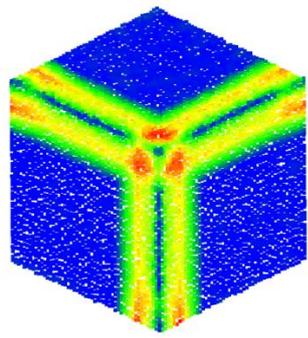
図 5.6 において DoN, DDoN, RDoN, RDoC では理想モデル 1-1 における結果と変わらず、ノイズに頑健な手法である。それに対し、DoC, DDoC では平面部に対しても特徴を示し、ノイズに弱いことがわかる。MS 特徴ではオクルージョンのある平面部に対して特徴を示しているため、オクルージョン部分に頑健でないことがわかる。提案手法では許容誤差距離が 1.5 では平面部にも特徴を示していたが、3.0 にすることでノイズに対して頑健になったことがわかる。このように提案手法では適当な許容誤差範囲を設定することでノイズに対しても頑健性を維持できると考えられる。

表 5.6 において、提案手法は従来手法よりも約 2 倍以上処理速度が向上していることがわかる。DoN, DoC, DDoN, DDoC, RDoN, RDoC では提案手法よりも約 2 倍の処理時間がかかり、MS 特徴では提案手法よりも約 4 倍の処理時間がかかった。DoN, DoC, DDoN, DDoC, RDoN, RDoC では近傍範囲を大小の二つ用いており、MS 特徴では近傍範囲を 7.5cm から 2.5cm ずつ 15.0cm まで四つの近傍範囲を用いているため、処理時間は用いる近傍範囲数によると考えられる。

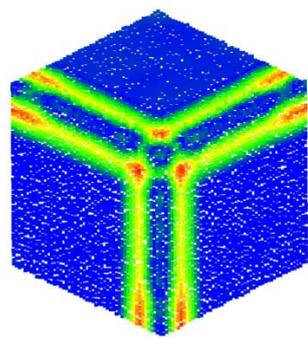
したがって提案した特徴抽出手法は従来手法よりも処理速度が速く，より細部にエッジを特徴として示すことができ，許容誤差距離を適当に設定することでノイズモデルに対して頑健な特徴抽出が可能である．

#### 5.4.2.2 自動閾値導出の実験結果及び考察

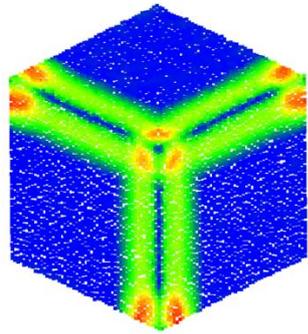
5.4.1.2 節で述べた実験を行う．理想モデル 1-3 及び計測モデルにおいて得られた特徴量結果を最小値が青，最大値が赤のヒートマップで図 5.7，図 5.8 に示す．また，点群 1 点あたりの処理時間を表 5.7 に示す．



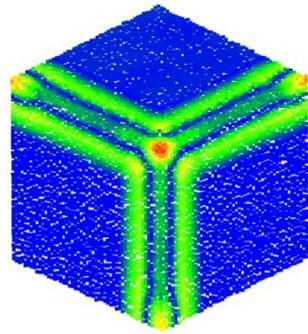
(a) DoN



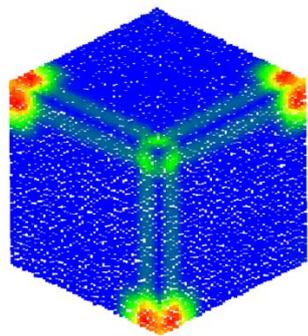
(b) DoC



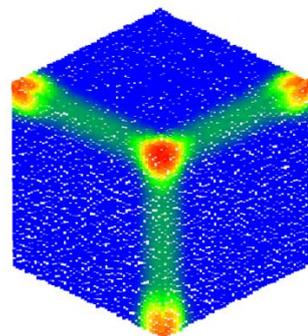
(c) DDoN



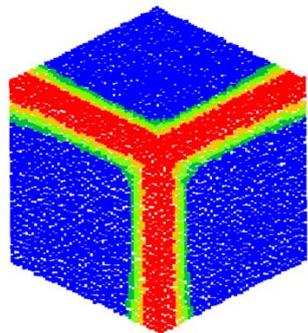
(d) DDoC



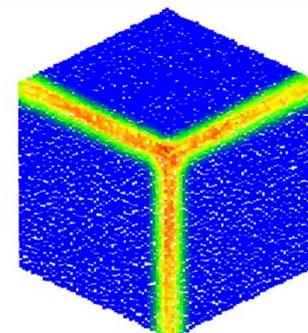
(e) RDoN



(f) RDoC

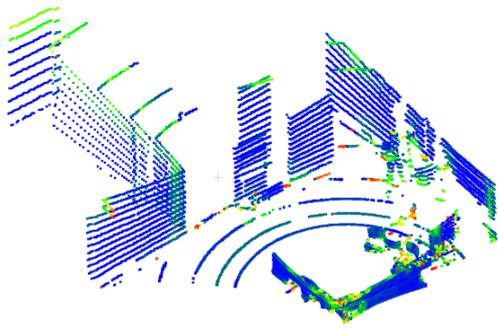


(g) MS 特徴

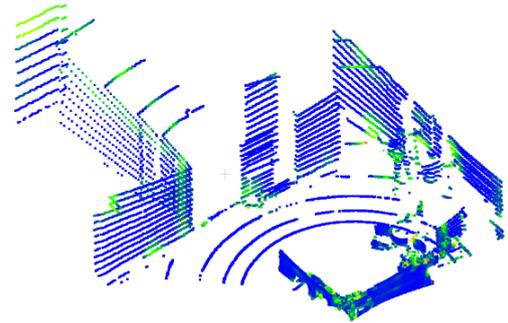


(h) 提案手法

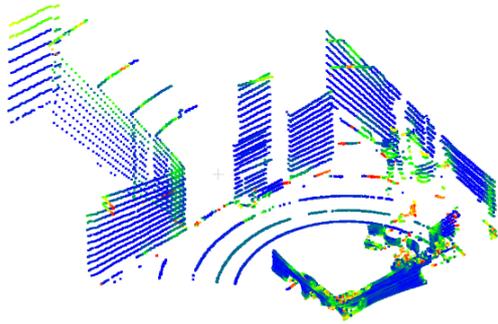
図 5.7 理想モデル 1-3 における特徴量カラーマップ



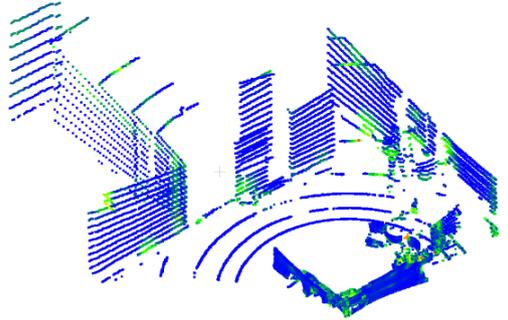
(a) DoN



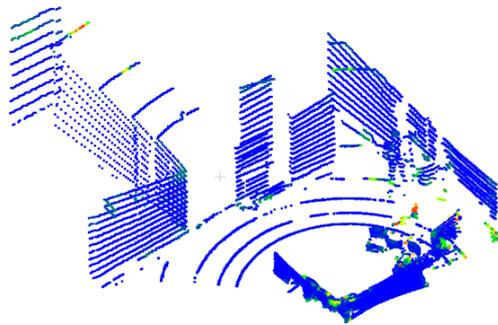
(b) DoC



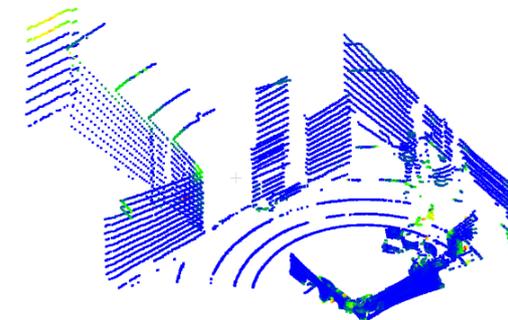
(c) DDoN



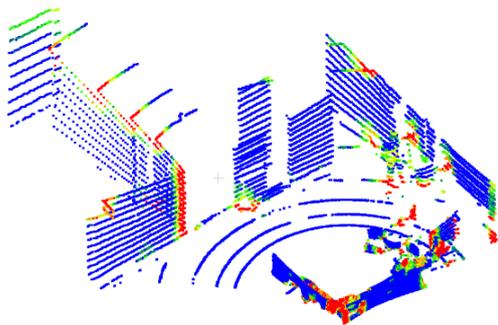
(d) DDoC



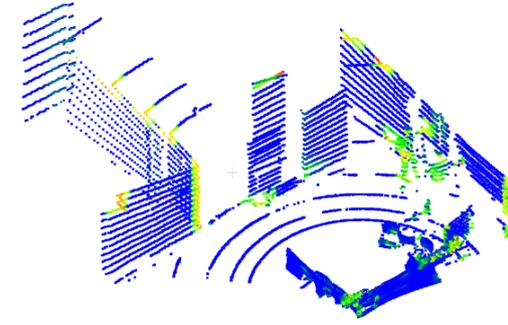
(e) RDoN



(f) RDoC



(g) MS 特徴



(h) 提案手法

図 5.8 計測モデルにおける特徴量カラーマップ

表 5.7 自動閾値導出を用いた特徴抽出の点群 1 点あたりの処理時間

手法	理想モデル 1-3 [ms]	計測モデル [ms]
DoN	0.517	0.456
DoC	0.495	0.445
DDoN	0.543	0.483
DDoC	0.516	0.455
RDoN	0.593	0.513
RDoC	0.566	0.496
MS 特徴	0.994	1.023
提案手法	0.251	0.231

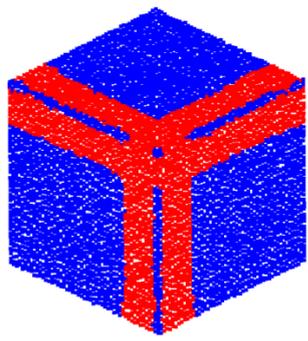
図 5.7 において、どの手法においても VLP-16 ノイズには頑健に特徴抽出を可能としている。これは LiDAR ノイズの大きさが一般ノイズほど大きくないからであると考えられる。提案手法では自動導出された閾値を用いても細部にエッジ特徴を示すことに成功している。したがって、自動導出手法も有効であると考えられる。

図 5.8 において、DoN, DoC, DDoN では理想モデルと同様にエッジ周辺に特徴を示す結果となった。RDoC においても理想モデルと同様にエッジの頂点に特徴を示した。しかし、DDoC では理想モデルではエッジに特徴を示したのに対し、計測モデルではエッジ周辺に特徴を示し、エッジにはあまり特徴を示さなかった。RDoN においてもエッジの頂点にあまり特徴を示さなかった。これらは理想モデルではエッジ周辺に点群が密に存在していたが、計測モデルではそれよりも疎であるからだと考えられる。MS 特徴及び提案手法では理想モデルと同様にエッジに特徴を示した。これらの結果より DoN, DoC, DDoN, RDoC, MS 特徴, 提案手法では実際に計測された点群に対しても適用できる手法であると考えられる。

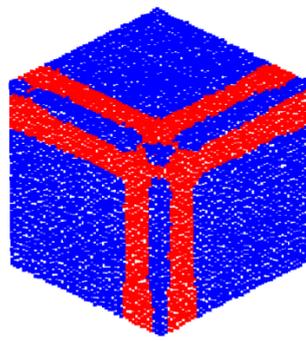
表 5.7 より点群 1 点あたりの処理時間は理想モデルより計測モデルのほうが少し早いことがわかる。これは計測モデルのほうが近傍点群数が少ないからであると考えられる。したがって点群 1 点あたりの処理時間は近傍点群数に依存し、全体の処理時間は近傍点群数及び全体の点群数に依存する。

### 5.4.2.3 エッジ判定の実験結果及び考察

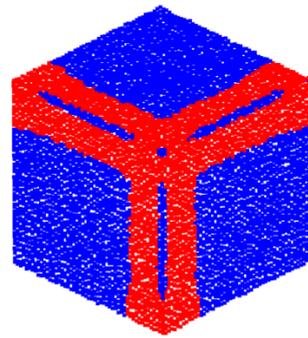
5.4.1.3 節で述べた実験を行う。理想モデル 1-3 において得られたエッジ判定結果を図 5.9, 図 5.10 に示す。ここでエッジ判定結果はエッジ判定部分を赤で、それ以外を青で示している。



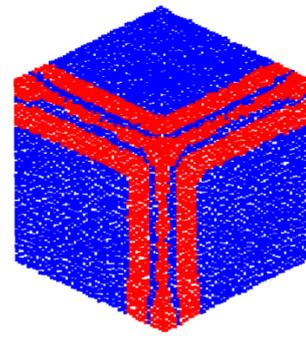
(a) DoN



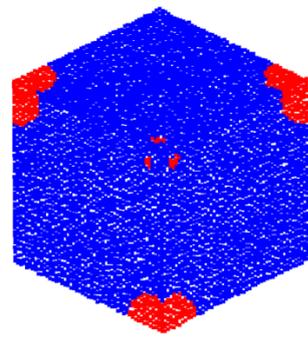
(b) DoC



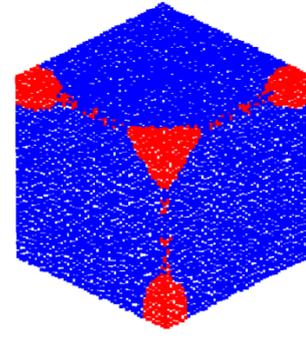
(c) DDoN



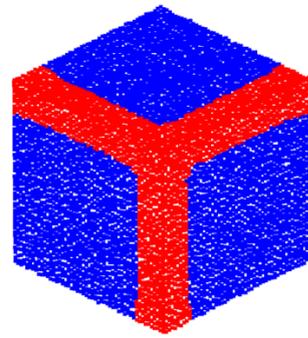
(d) DDoC



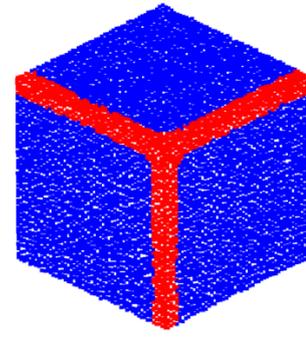
(e) RDoN



(f) RDoC

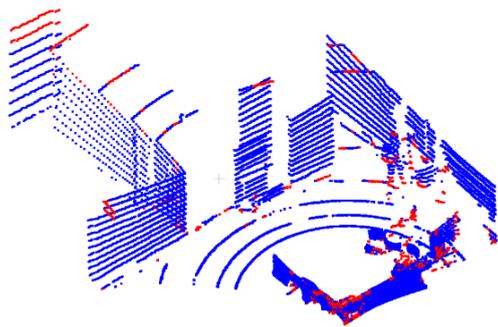


(g) MS 特徴

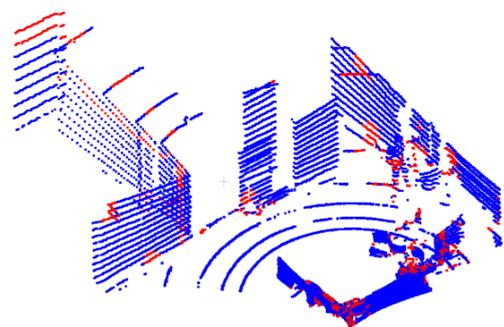


(h) 提案手法

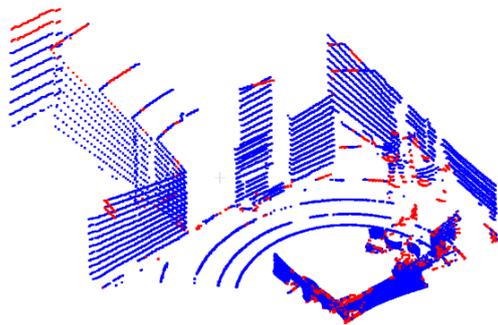
図 5.9 理想モデル 1-3 におけるエッジ判定結果



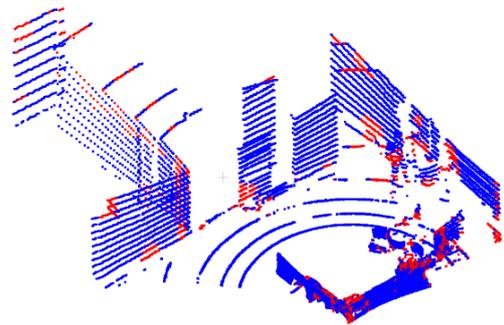
(a) DoN



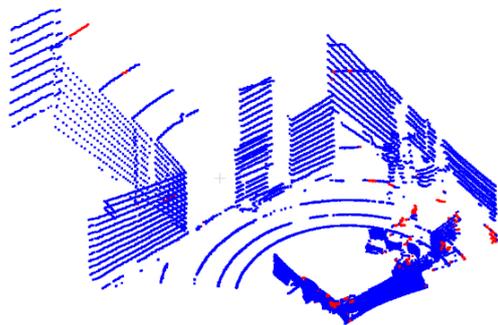
(b) DoC



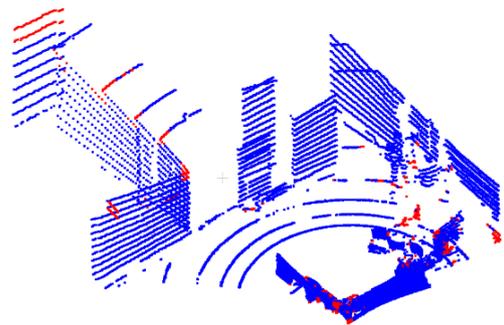
(c) DDoN



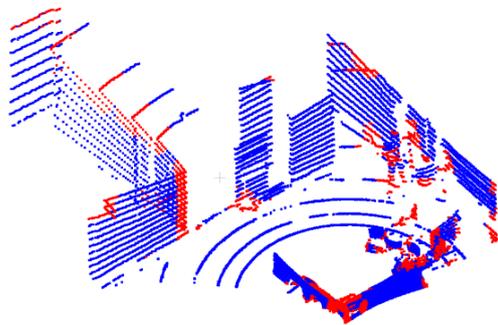
(d) DDoC



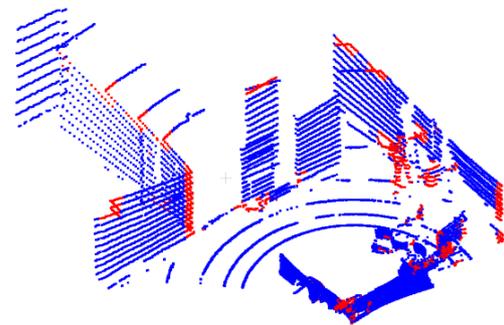
(e) RDoN



(f) RDoC



(g) MS 特徴



(h) 提案手法

図 5.10 計測モデルにおけるエッジ判定結果

図 5.9 からどの手法においても特徴量を二値化することに成功したことが確認できる。特徴抽出と同様に、DoN, DoC, DDoN ではエッジ周辺、DDoC ではエッジ及びエッジ周辺、RDoN ではオクルージョンのあるエッジの頂点付近、RDoC ではエッジの頂点付近、MS 特徴及び提案手法ではエッジがエッジ判定された。また、MS 特徴よりも提案手法のほうが細部にエッジ判定を可能としている。二値化結果からも提案手法は従来手法よりもエッジを細部に特徴抽出できることがわかる。

図 5.10 において、DoN, DoC, DDoN, DDoC, RDoN, RDoC では理想モデルと同じ結果を得ることができなかった。例えば DoN, DoC, DDoN ではエッジ周辺がエッジ判定されず、RDoN ではオクルージョンのあるエッジの頂点部分にエッジ判定がされなかった。それに対し MS 特徴及び提案手法では理想モデルと同様にエッジ部分がエッジ判定され、MS 特徴よりも提案手法のほうが細部にエッジ判定を可能としている。このことから DoN, DoC, DDoN, DDoC, RDoN, RDoC では実際に計測されたモデルに対しては頑健な特徴抽出が行えず、MS 特徴及び提案手法では計測モデルに対しても頑健な特徴抽出が可能であることがわかる。

二値化を行うことにより、各特徴抽出手法を数値的に評価する。理想モデルでは詳細なエッジ部分の点が変わるため、図 5.11 のようなエッジ判定の正解データを用意する。エッジ判定正解データをもとに、各手法のエッジ判定結果の適合率、再現率、F 値について表 5.8 に示す。

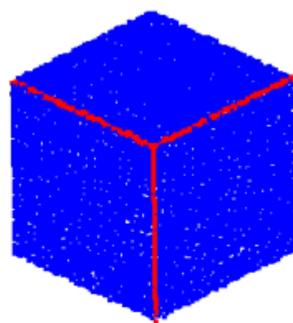


図 5.11 理想モデル 1-3 におけるエッジ判定正解データ

表 5.8 理想モデル 1-3 におけるエッジ判定正解データと各手法結果の比較

手法	適合率	再現率	F 値
DoN	0.021	0.19	0.038
DoC	0.015	0.11	0.028
DDoN	0.036	0.34	0.066
DDoC	0.11	0.98	0.20
RDoN	0.089	0.16	0.11
RDoC	0.20	0.68	0.31
MS 特徴	0.11	1.0	0.21
提案手法	0.21	1.0	0.34

表 5.8 より適合率, 再現率及び F 値において提案手法が最も高い数値を示している. また提案手法は平面領域も広いことから, 従来手法よりも細部に正しいエッジ判定が可能であることがわかる.

## 5.5 ノイズ整形実験

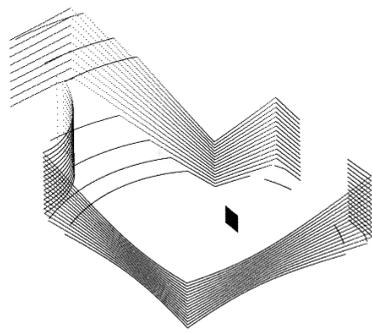
### 5.5.1 実験概要

4.3 節で述べたノイズ整形手法について, 理想モデル 2 及び計測モデルに従来手法及び提案手法を適用する. 提案手法を従来手法と比較することで, 提案手法の有効性を確認する. 従来手法は Bilateral, MLS, APSS 及び RIMLS を用いる. 提案手法におけるコサイン類似度の閾値は 45 度以内であれば同じ方向のベクトルであると考え,  $1/\sqrt{2}$  に設定した.

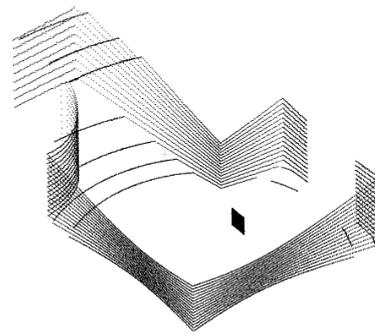
提案手法において, エッジ部処理と平面部処理を特徴抽出でのエッジ判定結果を用いて選択する場合と特徴量が 0 であるかでエッジ部処理と平面部処理を選択する場合の二つの場合について比較する.

### 5.5.2 実験結果及び考察

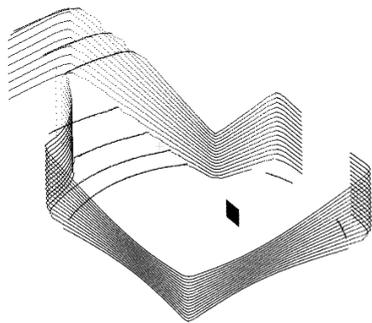
5.5.1 節の実験を行う. 理想モデル 2 に適用した結果の斜めからの図を図 5.12 に示し, 整形後のモデルを図 5.13 のように拡大した図を図 5.14 及び図 5.15 に示す. また, 計測モデルに適用した結果を図 5.16 に示す.



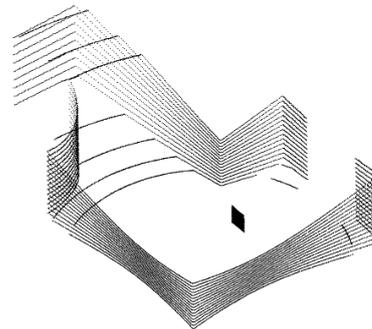
(a) 正解モデル



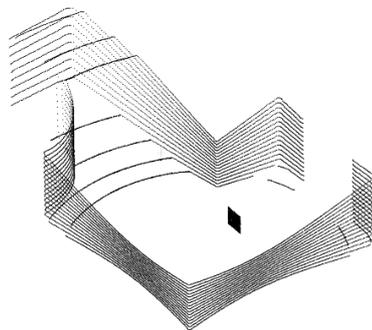
(b) LiDAR ノイズ付与



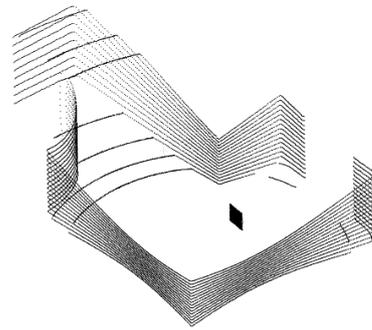
(c) Bilateral



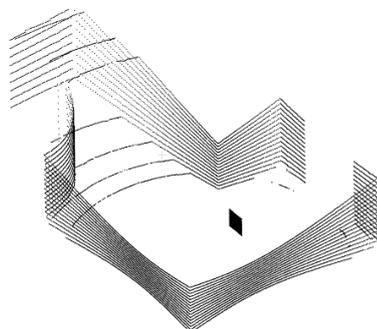
(d) MLS



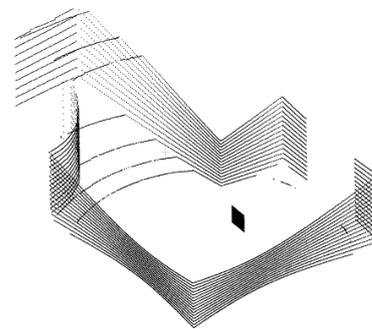
(e) APSS



(f) RIMLS



(g) 提案手法  
(判別分析法でエッジ判定)



(h) 提案手法  
(0でエッジ判定)

図 5.12 理想モデル2におけるノイズ整形結果

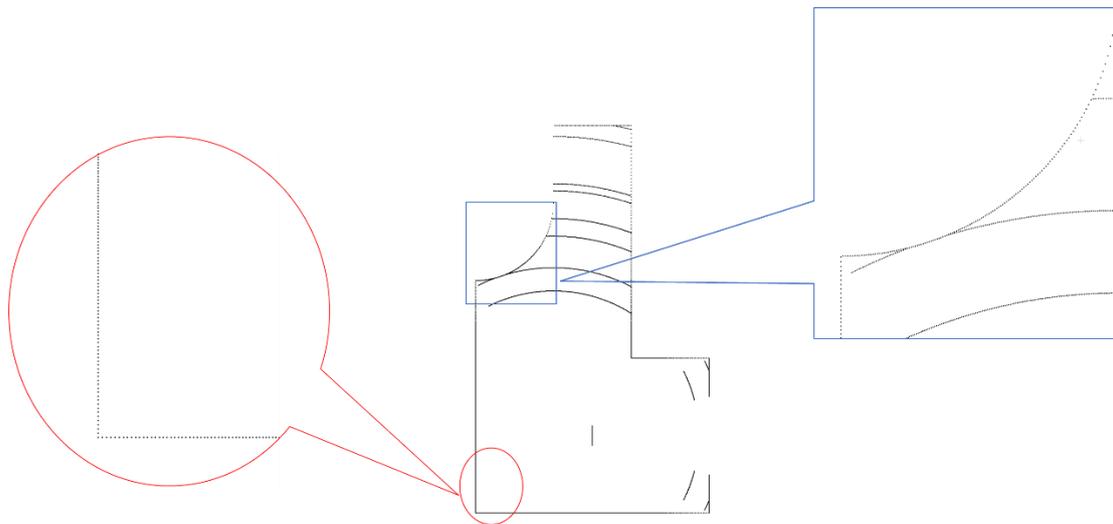


図 5.13 理想モデル 2 の拡大位置

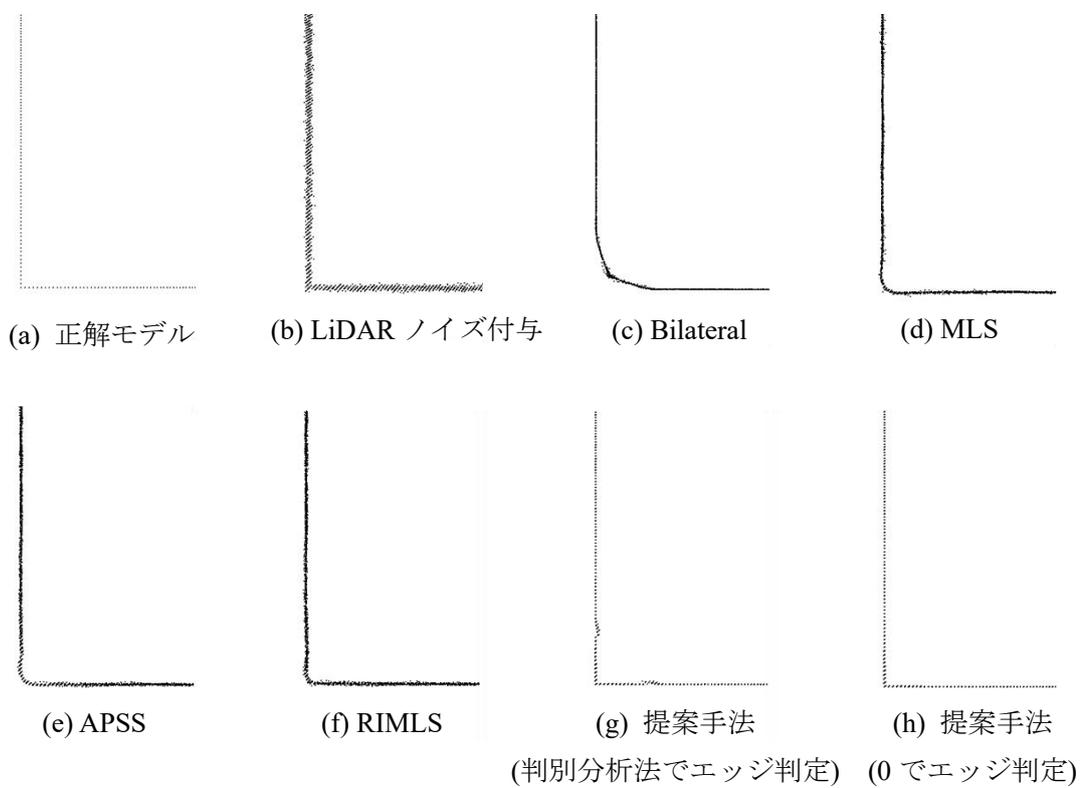
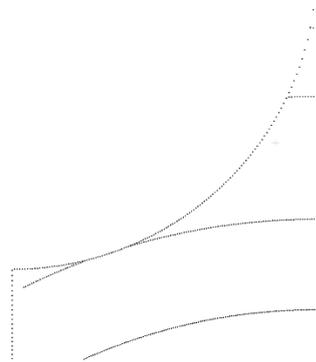
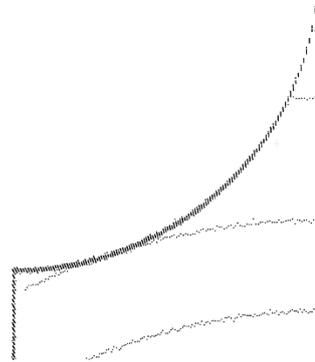


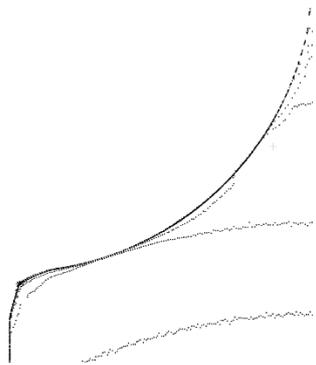
図 5.14 理想モデル 2 におけるノイズ整形結果の拡大図 1



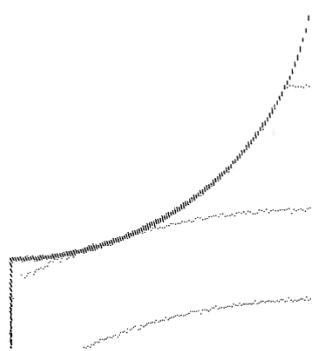
(a) 正解モデル



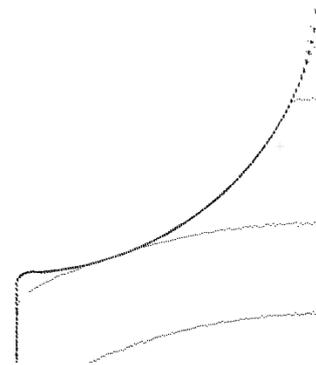
(b) LiDAR ノイズ付与



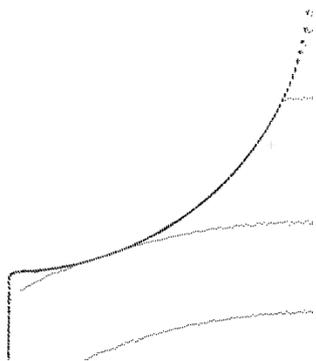
(c) Bilateral



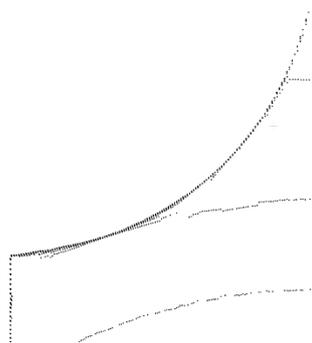
(d) MLS



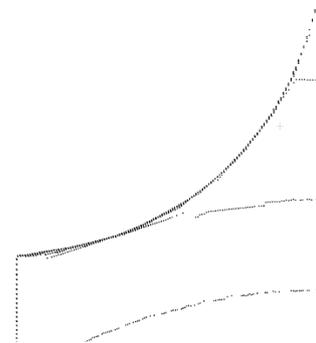
(e) APSS



(f) RIMLS

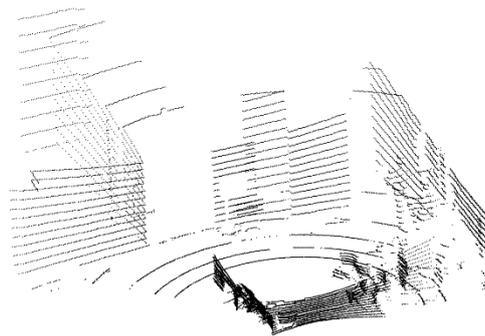


(g) 提案手法  
(判別分析法でエッジ判定)

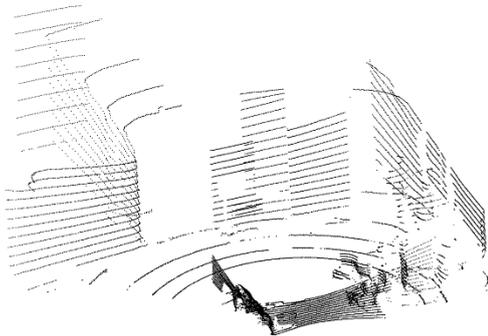


(h) 提案手法  
(0でエッジ判定)

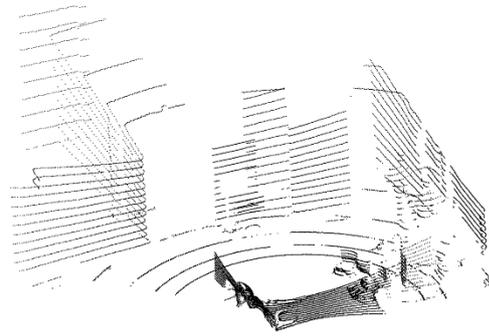
図 5.15 理想モデル2におけるノイズ整形結果の拡大図2



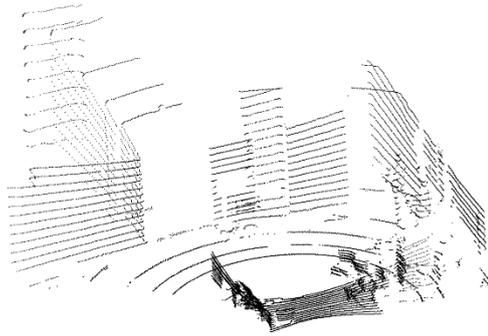
(a) 計測モデル



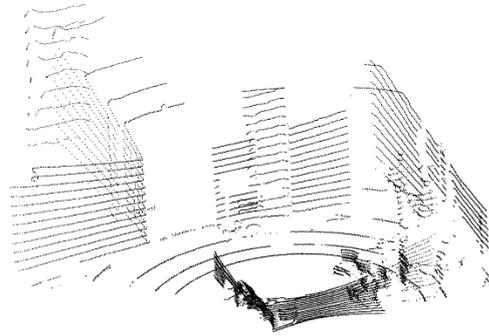
(b) Bilateral



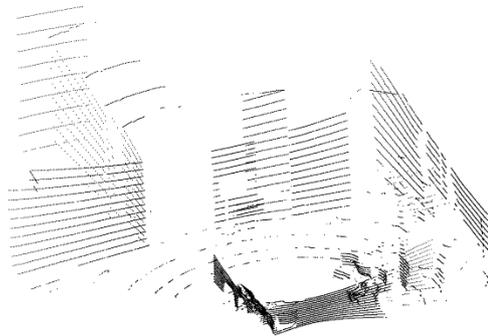
(c) MLS



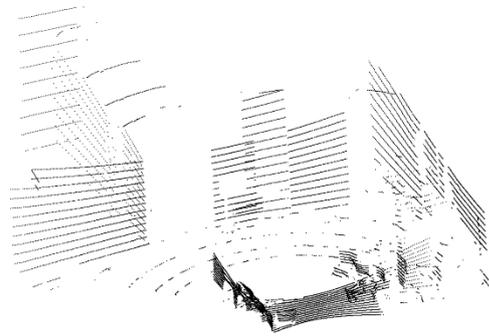
(d) APSS



(e) RIMLS



(f) 提案手法  
(判別分析法でエッジ判定)



(g) 提案手法  
(0でエッジ判定)

図 5.16 計測モデルにおけるノイズ整形結果

図 5.12, 図 5.14 及び図 5.15 より, Bilateral は面を滑らかに整形しているがエッジを過度に滑らかにするという特徴がある. MLS, APSS, RIMLS では Bilateral よりもエッジを残した整形が可能であるが平面において滑らかに整形できない特徴がある. これらに対し, 提案手法では, エッジを残して滑らかな面整形が可能であることがわかる. 提案手法でのエッジ判定において, 0 でエッジ判定を行った場合は滑らかな整形を可能としているが, 判別分析法でエッジ判定を行った場合はエッジ付近にずれた整形が見られる. これは算出された平面方程式がその部分ではエッジの影響で平面からずれてしまったためであると考えられる. また, 提案手法ではエッジを残した滑らかな面整形を可能としたが, 曲面における整形のずれや, 外れた値を除去しているために整形後の点群が元々の点群よりも疎になるという問題がある. これはすべての整形に平面方程式しか用いていないことが原因であると考えられる. 平面方程式だけでなく, 球面や曲面に対応させた方法も取り入れることでさらにノイズ整形の精度向上が期待できる.

図 5.16 より, 各手法は計測モデルにも適用でき, 理想モデルと同じ特徴を示すことがわかる. しかし APSS, RIMLS では歪んで整形された部分があった. これは計測原点から近い計測点と遠い計測点では点の疎密具合が異なるためであると考えられる. これに対し, 提案手法では計測点の距離, つまり点の疎密に依存せずにエッジを残した整形を可能としている. よって提案手法は理想的なモデルだけでなく, 実際に計測されたモデルに対しても有効性を確認することができた.

ノイズ整形結果の定性的な評価を行った. 次に定量的評価を行う. 理想モデル 2 においては正解モデルがわかっているため, ノイズ整形点の正解モデルの最近傍点との誤差距離, 理想面に対しての誤差距離を計算する. 得られた誤差距離の平均誤差及び最大誤差をそれぞれ表 5.9, 表 5.10 に示す. ここで LiDAR ノイズ付与データの誤差も計算することで, 各手法の理想モデルへの整形具合を確認することができる.

表 5.9 理想モデル 2 における各点の理想最近傍点との誤差距離

手法	平均誤差 [m]	最大誤差 [m]
LiDAR ノイズ付与	0.00595	0.0422
Bilateral	0.00640	0.186
MLS	0.00384	0.0302
APSS	0.00401	0.106
RIMLS	0.00420	0.0626
提案手法 (判定分析法でエッジ判定)	0.00210	0.0437
提案手法 (0 でエッジ判定)	0.00187	0.0437

表 5.10 理想モデル2における各点の理想面との誤差距離

手法	平均誤差 [m]	最大誤差 [m]
LiDAR ノイズ付与	0.00465	0.0412
Bilateral	0.00436	1.00
MLS	0.00197	0.0291
APSS	0.00243	0.999
RIMLS	0.00250	0.477
提案手法 (判定分析法でエッジ判定)	0.00133	0.0399
提案手法 (0 でエッジ判定)	0.00115	0.0399

表 5.9 及び 5.10 より 0 でエッジ判定を行った提案手法が最も理想的なモデルに整形していることが確認できる。Bilateral では滑らかな整形を可能としているが、エッジも過度に整形してしまうため、元々のノイズよりも最大誤差が大きくなっていることがわかる。ほかにも APSS や RIMLS では全体での滑らかな整形を可能としているが元々のノイズよりも誤差を大きくした点も存在することがわかる。提案手法では従来手法よりも平均誤差を大幅に減少させたことが確認できる。したがって、提案手法が最も理想モデルに近い整形が可能である。しかし、提案手法での最大誤差は元々のノイズとあまり変わらないことがわかる。これは平面やエッジに対する精度は向上したが、曲面に対して精度が向上できなかったことが原因であると考えられる。

## 5.6 むすび

本章では第 4 章の提案手法に対する評価実験を行った。また、従来手法と比較し提案手法の有効性を確認した。

## 第6章 結論と今後の課題

### 6.1 結論

本論文では LiDAR で計測された点群に対する特徴抽出手法及び得られた特徴量を用いたノイズ整形手法を提案した。

特徴抽出では従来手法では複数の近傍範囲を用いていたが、提案手法では近傍範囲を一つだけ用いることで処理速度を向上させ、さらに詳細な特徴抽出を可能とした。また、LiDAR で計測された点群のノイズ特性を調べることで特徴抽出における近傍範囲及び閾値の自動導出を可能とした。これにより設定する近傍範囲や閾値に依存することなく入力点群に対し毎回同じ結果を取得することができる。また詳細なエッジ情報を抽出できることから、エッジ部と平面部のセグメンテーションを可能とした。

ノイズ整形手法ではエッジ情報を用いてエッジ部と平面部で異なる処理をすることでノイズ整形の精度向上に成功した。従来手法よりもエッジを残した面整形を可能とし、理想面との誤差も大幅に減少することに成功した。

### 6.2 今後の課題

今後の課題として二つ挙げられる。

一つ目は特徴抽出においてエッジだけでなく曲面と平面を判別できるように特徴を抽出することである。これによりモデルのより詳細な形状を把握することができ、物体検出などにも応用が可能であると考えられる。

二つ目はノイズ整形において、平面方程式以外の式でモデルを近似することである。本研究において曲面の整形において著しい精度向上が見られないという問題点があった。これはノイズ整形が平面方程式でのみ処理されていることが原因であると考えられる。平面方程式だけでなく、曲面の方程式も用いることでノイズ整形のさらなる精度向上が可能であると考えられる。

以上二つの課題に取り組む必要があると考えられる。また、今後ドローンなどに LiDAR を乗せて点群取得とノイズ整形を同時に行っていくことでノイズの少ない大規模点群の取得が可能であると考えられるため、ノイズ整形手法の処理速度向上も今後の課題として考えられる。

## 謝辞

本研究のテーマ設定や方向性，また問題点の提起や整理など丁寧かつ適切なご指導くださった渡辺裕教授と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深く感謝申し上げます。

また，ゼミ合宿で様々な角度からのご意見，ご指導くださった亀山渉教授と笠井裕之教授に感謝致します。

さらに日頃から問題点解決の相談に乗っていただき，貴重なご意見をくださった研究室の皆様にお礼申し上げます。特に同期である松田卓也氏，稲田健太郎氏，梅田聖也氏には日頃のストレス発散や研究に関する密な意見交換をしていただき大変お世話になりました。

最後に，これまで育てていただき，学業に専念させてくださった家族に心より感謝致します。

## 参考文献

- [1]. 公益財団法人日本自動車教育振興財団, “Traffi-Cation,” Vol.42, pp.2-6, June 2016.
- [2]. 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.
- [3]. Y.Ioannou, B.Taati, R.Hrrap, M.Green, “Difference of Normals as a Multi-scale Operator in Unorganized Point Clouds,” 2012 Second International Conference on 3D Imaging, Modeling, Processing, Visualization and Transmission, pp.501-508, Oct. 2012.
- [4]. 早田, 岩田, “3次元点群からのマルチスケール特徴抽出法に関する検討”, 情報処理学会オーディオビジュアル複合処理研究会報告(AVM), Vol.2015-AVM-89, No.7, pp.1-6, Aug. 2015.
- [5]. M.Pauly, R.Keiser, M.Gross, “Multi-scale Feature Extraction on Point-Samples Surfaces,” Computer graphics forum, Vol.22, No.3, pp.281-289, Nov. 2003.
- [6]. W.Huang, Y.Lin, P.Wen, X.Wu, “Algorithm for 3D Point Cloud Denoising,” 2009 Third International Conference on Genetic and Evolutionary Computing, pp.574-577, Oct. 2009.
- [7]. F.Yan, Z.Jinlei, “Research on scattered points cloud denoising algorithm,” 2015 IEEE International Conference on Signal Processing, Communications and Computing(ICSPCC), Sept. 2015.
- [8]. D.Levin, “Mesh-Independent Surface Interpolation,” Geometric Modeling for Scientific Visualization, pp.37-49, Jan. 2003.
- [9]. G.Guennebaud, M.Gross, “Algebraic point set surfaces,” SIGGRAPH '07: ACM SIGGRAPH 2007 papers, Vol.26, No.3, July 2007.
- [10]. A.C.Oztireli, G.GUennebaud, M.Gross, “Feature preserving point set surfaces based on nonlinear kernel regression,” Computer Graphics Forum, Vol.28, No.2, pp.493-501, Apr. 2009.
- [11]. J.Digne, Garlo de Franchis, “The Bilateral Filter for Point Clouds,” Image Processing On Line, Vol.7, pp.278-287, Oct. 2017.
- [12]. M.Pauly, M.Gross, L.P.Kobbelt, “Efficient simplification of point-sampled surfaces,” Proceedings of the conference on Visualization '02, pp.163-170, Oct. 2002.
- [13]. 大津展之, “判別および最小2乗基準に基づく自動しきい値選定法,” 電子情報通信学会論文誌D, Vol.J63-D, No.4, pp.349-356, Apr. 1980.

## 図一覧

図 2.1	点群における主成分分析.....	5
図 3.1	VLP-16.....	8
図 3.2	VLP-16 のレーザー照射.....	9
図 3.3	ノイズ特性実験環境図.....	10
図 3.4	算出する誤差距離.....	10
図 3.5	計測されたデータの誤差分布.....	11
図 4.1	特徴抽出手法概念図.....	13
図 4.2	正規分布例.....	15
図 4.3	エッジ部周辺図.....	17
図 5.1	単純な理想モデル.....	21
図 5.2	現実空間に近い理想モデル(ノイズ無し).....	21
図 5.3	計測場所.....	22
図 5.4	計測した現実空間モデル.....	22
図 5.5	理想モデル 1-1 における特徴量カラーマップ.....	27
図 5.6	理想モデル 1-2 における特徴量カラーマップ.....	28
図 5.7	理想モデル 1-3 における特徴量カラーマップ.....	31
図 5.8	計測モデルにおける特徴量カラーマップ.....	32
図 5.9	理想モデル 1-3 におけるエッジ判定結果.....	34
図 5.10	計測モデルにおけるエッジ判定結果.....	35
図 5.11	理想モデル 1-3 におけるエッジ判定正解データ.....	36
図 5.12	理想モデル 2 におけるノイズ整形結果.....	38
図 5.13	理想モデル 2 の拡大位置.....	39
図 5.14	理想モデル 2 におけるノイズ整形結果の拡大図 1.....	39
図 5.15	理想モデル 2 におけるノイズ整形結果の拡大図 2.....	40
図 5.16	計測モデルにおけるノイズ整形結果.....	41

## 表一覧

表 5.1	実験環境 .....	20
表 5.2	モデル一覧 .....	23
表 5.3	特徴抽出実験で用いるパラメータ .....	23
表 5.4	理想モデル 1-3 での自動閾値導出実験で用いるパラメータ .....	25
表 5.5	計測モデルでの自動閾値導出実験で用いるパラメータ .....	25
表 5.6	特徴抽出の点群 1 点あたりの処理時間 .....	29
表 5.7	自動閾値導出を用いた特徴抽出の点群 1 点あたりの処理時間 .....	33
表 5.8	理想モデル 1-3 におけるエッジ判定正解データと各手法結果の比較 .....	37
表 5.9	理想モデル 2 における各点の理想最近傍点との誤差距離 .....	42
表 5.10	理想モデル 2 における各点の理想面との誤差距離 .....	43

## 研究業績

- [1]. 赤塚, 渡辺: “LiDAR と全天球画像を用いた三次元再構成 (3D Reconstruction Using LiDAR and Omni-directional Image)”, 情報処理学会全国大会, 2U-04, Mar. 2018
- [2]. 赤塚, 原, 渡辺: “全天球画像特徴を用いた 3D 点群境界検出 (Boundary Detection of 3D Point Clouds Using Omni Image Features)”, 2018 年画像符号化シンポジウム・2018 年映像メディア処理シンポジウム (PCSJ/IMPS2018), P-3-9, Nov. 2018
- [3]. 赤塚, 原, 渡辺: “全天球画像特徴を用いた 3D 点群ノイズ整形 (Noise Shaping of 3D Point Clouds Using Omni Image Features) “, 2018 年映像情報メディア学会冬季大会, 11D-5, Dec. 2018
- [4]. 赤塚, 原, 渡辺: ” 主成分分析を用いた点群特徴抽出に関する一検討 (Study on Feature Extraction of Point Cloud Using Principal Component Analysis)”, 情報処理学会オーディオビジュアル複合情報処理研究会, AVM104-003, Feb. 2019
- [5]. 赤塚, 原, 渡辺: ” 点群特徴抽出に関する一検討 (A Study on Feature Extraction of Point Cloud) “, 電子情報通信学会総合大会, D-12-39, Mar. 2019
- [6]. 赤塚, 原, 渡辺: ” 点群ノイズ処理のための点群特徴抽出 (Feature Extraction of Point Cloud for Noise Shaping of Point Cloud) “, 情報処理学会オーディオビジュアル複合情報処理 (AVM) 研究会研究報告, Vol.2019-AVM105, No.13, pp.1-4, June 2019

## 受賞

- [1]. オーディオビジュアル複合情報処理研究会 2018 年度 AVM 賞優秀賞, 情報処理学会,  
Feb. 2019