

リバースエンジニアリングのための 教師なし機械学習による 形状測定点群データのセグメンテーション

松田 優也^{1,a)} 小高 知宏²

受付日 2020年10月16日, 採録日 2021年4月6日

概要: 製造業の現場での 3D スキャナや X 線 CT 等の普及にともない, 形状測定点群データを元にして 3 次元 CAD データのサーフェスを生成するリバースエンジニアリング技術の開発がこれまで行われてきた. リバースエンジニアリングでのサーフェス生成のためには CAD データの構成に合わせた点群のセグメンテーションが必須となるが, 既存手法では手動による作業が必要になる場合が多く, コスト削減のため自動化が求められている. そこで本研究では点群の座標成分, 法線成分, 法線成分の分散を特徴量とし, VBGMM と DBSCAN によるクラスタリングをあわせて適用することで, 点群のセグメンテーションを自動化する手法を考案したので報告する.

キーワード: 形状測定点群, セグメンテーション, 教師なし機械学習, クラスタリング

Segmentation of Point Clouds for Reverse Engineering Using Unsupervised Machine Learning

YUYA MATSUDA^{1,a)} TOMOHIRO ODAKA²

Received: October 16, 2020, Accepted: April 6, 2021

Abstract: Along with the widespread use of 3D scanners and X-ray CT scanners on manufacturing scenes, reverse engineering technique creating surfaces for 3D CAD data has been developed so far. To create surfaces on reverse engineering, segmentation of point clouds which suits surface configuration of 3D CAD data is needed, however, it costs a lot with conventional manual operations, and hence, development of automatic segmentation is required to cut costs. In this manuscript, our new method is presented, which automates the segmentation of point clouds with a combination of the clustering based on the VBGMM and the DBSCAN, where, points, normals, and variances of normals are treated as feature vectors.

Keywords: point cloud, segmentation, unsupervised machine learning, clustering

1. はじめに

近年の製造業の現場での 3D スキャナや X 線 CT 等の普及にともない, 形状測定点群データを元にして 3 次元 CAD データのサーフェスを生成するリバースエンジニアリング

技術の開発がこれまで行われてきた. リバースエンジニアリングにより 3 次元 CAD データを作成することで, 機械加工により同一形状のパーツが複製できるだけでなく, 部分的に CAD データを編集することにより類似形状のパーツ設計に利用できる. また, 構造解析や流体解析等の目的で CAE を利用する際には解析メッシュの生成のため 3 次元 CAD データが必要となるが, 試作品や他社製品の現物から形状測定点群データを取得し, リバースエンジニアリングにより 3 次元 CAD データを作成すれば CAE による解析が可能になる. このように, リバースエンジニアリン

¹ 福井県工業技術センター
Industrial Technology Center of Fukui Prefecture, Fukui
910-0102, Japan

² 福井大学
University of Fukui, Fukui 910-8507, Japan

^{a)} y-matsuda@fklab.fukui.fukui.jp

グにより 3 次元 CAD データを作成することで得られるメリットは大きい。

リバースエンジニアリングによるサーフェス生成は一般的に以下の手順により行われる。

- 3D スキャナ等により形状測定点群データを取得
- 形状測定点群データをポリゴン (STL 形式等) に変換
- 形状測定点群データのノイズ除去と穴埋め処理
- CAD データのサーフェス構成に合わせて点群を分割
- セグメンテーションごとにサーフェスを生成

以上のように、リバースエンジニアリングでは点群データを元にしてサーフェスを生成するため、CAD データのサーフェス構成に合わせた点群のセグメンテーションが必須となる。しかし既存手法では手動による作業が必要になる場合が多く、完全な自動処理によりセグメンテーションが完了できるケースは限られている。点群のセグメンテーションはリバースエンジニアリングのプロセスのボトルネックとなっており、リバースエンジニアリングのコスト削減のために自動化が求められている。

そこで形状データのセグメンテーションの自動化のために様々な手法が考案されている。従来手法には、点群データをセグメンテーションするもの (2.1 節参照)、メッシュデータをセグメンテーションするもの (2.2 節参照) がある。前者はエッジのような特徴的な境界を認識することを目指すものが多く、接線連続の境界を抽出することは難しい。後者は形状データを意味的な領域に分割するものが多く、リバースエンジニアリングには不向きである。また両者とも形状測定データのノイズ等、データ品質の影響を大きく受ける。深層学習を利用したセグメンテーション手法も考案されている (2.3 節参照) が、ラベル付けされた大量の学習データを必要とするという問題がある。

これらの従来手法に対して、本研究では点群のエッジ抽出手法や学習データを用いることなく、教師なし機械学習の一手法であるクラスタリングのみを用いることで点群のセグメンテーションを行う手法を考案した [1], [2]。提案手法ではエッジ境界のような位置連続の境界だけではなく、より滑らかな接線連続の境界でのセグメンテーションも可能である。

提案手法の有効性を評価するために、人工的な点群データと実際の形状測定点群データを用いてセグメンテーションの実験を行った。その結果、位置連続の境界と接線連続の境界でセグメンテーションが可能であることを確認した。本研究の貢献は次のとおりである。

- CAD データのサーフェス構成に合わせた点群のセグメンテーションのための、位置連続および接線連続の境界でのセグメンテーション手法の提案。
- 学習データを必要としない、クラスタリングのみによるセグメンテーション手法の提案。
- ノイズの除去等のデータ修正を必要としないセグメン

テーション手法の提案。

2. 従来手法

2.1 点群のセグメンテーションの先行研究

形状測定点群のセグメンテーションのための手法はこれまでに数多くの研究がなされてきており、種々の手法をまとめたサーベイ論文も発表されてきている。Nguyen ら [3] は既存の点群のセグメンテーション手法をエッジベース、領域ベース、モデルベース、グラフベース、属性ベースの 5 つに分類した。エッジベースの手法は点群のセグメンテーション境界となるエッジに対応する点群を抽出する。たとえば Gumhold ら [4] は点群から作成した近傍グラフを利用してエッジを抽出した。また M  rigot ら [5] は注目点のボロノイセルの共分散行列から法線や曲率を推定しエッジを抽出した。領域ベースの手法は特徴の近い点を取り込みながら領域を拡大し点群全体を分割する。Rabbani ら [6] は最初に選択したシード点から法線の変化量を調べながら領域を拡大する手法を考案した。モデルベースの手法は球、円筒、平面といったプリミティブな形状を利用し、同じプリミティブ形状に属する点群を同じグループに分類する。有名な手法として RANSAC と呼ばれるプリミティブ形状を点群に当てはめることで点群を検出する手法があり、多くの派生アルゴリズムが存在する。Schnabel ら [7] は RANSAC のボトルネックとなる点群のサンプリング等の処理を最適化することで速度と精度の両立を図った。グラフベースの手法は隣接関係にある点をエッジで接続することで点群をグラフ構造に変換し、グラフカットにより点群を分割する。Golovinskiy ら [8] は点群から 3 次元グラフを構築するために k-Nearest Neighbors (k-NN) を使用し、Min-Cut という手法でグラフを分割した。

エッジベースと領域ベースの手法は曲率の大きい領域をエッジとして認識し、エッジを境界としてセグメンテーションを行う。それゆえ接線連続で接続するような滑らかな接続面に対応する点群の境界でセグメンテーションすることは困難であると考えられる。またモデルベースの手法はノイズに強いというメリットはあるものの、平面や球や円筒等のプリミティブ形状のみ対象としており、プリミティブ以外の自由曲面に対応する点群についてはセグメンテーションの対象外となる。グラフベースの手法の多くは物体検出のために背景から前景にある対象となる点群を分離することを目的としており、リバースエンジニアリングには適さない。

2.2 メッシュデータのセグメンテーションの先行研究

点群のセグメンテーションと関わり深い技術であるメッシュデータのセグメンテーションについてもこれまで多くの研究が行われてきた。メッシュデータは CAD データのサーフェスを近似的にポリゴンで置き換えることで

生成できるほか、一般的な非接触型の 3D スキャナの出力データとして得られる。点群が位置座標値を持つ点の集合であるのに対し、メッシュデータは隣接点がエッジで結ばれた細かな三角形の集合として表現されるという違いがある。また通常はメッシュデータの面の裏表が区別される。

Rodrigues ら [9] のサーベイ論文に見られるように、メッシュデータのセグメンテーションには種々の方法が存在する。文献 [9] ではセグメンテーション手法を Volume based, Surface based, Skeleton based の 3 種に分類しているが、いずれも Part based, すなわち形状データを意味のあるまとまりごとの部品に分解する手法であるため、リバースエンジニアリングで必要となるサーフェス生成を考慮したセグメンテーションは達成されない。Yamakawa ら [10] は CAD データから生成したメッシュデータのフィレット中心線を抽出し、領域成長法を用いてセグメンテーションする手法を考案した。しかしリバースエンジニアリングにおいては、フィレットに限らず一般的な接線連続の境界での分離もできることが望ましい。Mejia ら [11] はメッシュデータの幾何学的な情報と位相的な情報の両方を利用したセグメンテーションの自動化手法を考案し、メッシュデータの過分割と巨大なセグメントの発生の回避に成功しているが、前提としてメッシュデータに形状測定データ特有のエラーがないことが要求される。

2.3 深層学習によるセグメンテーションの先行研究

近年では深層学習を用いたメッシュデータのセグメンテーション手法が考案されている。Biesbroeck ら [12] はメッシュ化したシンプルな形状の CAD データについてセグメンテーション済みのデータセットを作成し、深層学習を適用する実験を行った。Muraleedharan ら [13] はオートエンコーダによりメッシュ化した CAD データの特徴抽出を行うことで、セグメンテーションされたパーツごとに形状の分類を行った。Le ら [14] は空間内のグリッドごとにサンプリングした任意の個数の点を入力とする PointGrid と呼ばれる手法を用いて、深層学習によりセグメンテーションおよび形状の分類を行った。文献 [12], [13], [14] のような深層学習を利用したセグメンテーション手法は CAD データから生成した STL を対象としているため、形状測定により得られた形状測定点群データに対して同様の手法を適用することは難しい。Qi ら [15], [16] は PointNet と呼ばれるニューラルネットワークを提案しており、CAD データから生成したデータだけでなく Kinect から得られた形状測定点群データの分類タスクにも成功しているが、文献 [12], [13], [14] と同様にセグメンテーション済みで各セグメントにラベルが付けられた大量の学習データを必要とする。

2.4 データ修正の必要性

実用化されているものも含めた従来手法による点群のセグメンテーションにおいては、前述のエッジベースまたは領域ベースの手法によるものが多い。エッジベース手法では曲率の計算が必要となるが、曲率は 2 次微分量でありノイズの影響を受けやすいため、はじめに点群から測定データのノイズ除去や凹凸のスムージングを行うことが必要となる。それゆえノイズ除去やスムージングが不十分な場合等、何らかの理由で特徴抽出に失敗した場合はセグメンテーションができないという問題がある。また領域ベースによる手法においても、ノイズや点群データの欠損の影響により同一領域の誤抽出が発生する場合がある。実際、リバースエンジニアリングのための商用ソフトウェアとしては Geomagic Design X [17] が最も有名であるが、同ソフトウェアでのリバースエンジニアリングにおいても形状測定点群データの品質の影響は大きく、ノイズの除去だけでなく点群データに欠損がある場合には人工的な穴埋めが必要となる [18]。

3. 提案手法

本章ではまず教師なし学習のクラスタリング手法とクラスタリングに用いる特徴量ベクトルについて述べる。次に提案手法のセグメンテーションアルゴリズムの概要を示し、続いて位置連続、接線連続の境界でのセグメンテーション手法について詳しく説明する。最後に提案手法におけるエッジ部分の点群の取り扱いに関する考え方を述べる。

3.1 クラスタリング

3.1.1 教師なし機械学習

機械学習は教師あり学習と教師なし学習に大別される。両者の違いは正解となる教師データの有無であり、教師なし学習においてはデータの持つ全体的な構造から意味のある情報を抽出する手法の総称である。その中でクラスタリングは教師なし学習の代表的な手法に位置づけられる。本研究で取り扱う点群のセグメンテーションのような問題では当然のことながら教師データは存在せず、データすなわち各測定点の持つ全体的な構造からセグメンテーション結果を推論する必要がある。

3.1.2 クラスタリング手法

クラスタリングには様々な既存手法が存在する。代表的なクラスタリング手法として k 平均法 [19] が知られているが、k 平均法ではあらかじめクラスタ数を指定する必要がある。しかし点群のセグメンテーションでは、元の形状が複雑であるほどクラスタ数を事前に把握することは困難である。

提案手法では変分混合ガウス分布 (VBGM: Variational Bayesian Gaussian Mixture) [20] と DBSCAN (Density-based spatial clustering of applications with




図 1 VBGMM (左) と DBSCAN (右) によるクラスタリング結果の比較

Fig. 1 A comparison between VBGMM (left) and DBSCAN (right).

noise) [21] を使用するが、これらはいずれもあらかじめクラスタ数を指定する必要がないという長所がある。

また、VBGMM ではデータの分布としてガウス分布を仮定しており、外れ値を持つデータをノイズとして省くことが容易である。一方、DBSCAN ではデータの分布として楕円形を仮定しないため、分布の形状が複雑なデータにも適用できる (図 1)。

そこで提案手法では、図 1 上段のように塊状に集積したデータ点から外れ値を排除しつつクラスタを抽出する場合に VBGMM を使用する。また、図 1 中段および下段のように形状は複雑だがひと続きの島をなしている集積したデータ点をクラスタとして抽出する場合に DBSCAN を使用する。

3.2 特徴量ベクトル

クラスタリングによりデータをラベル付けするためには各データが何らかのベクトルデータとなっている必要がある。点群のセグメンテーションにおいてははじめ各点が 3 成分の位置座標ベクトルを保持しており特徴量とすることができる。すなわちある点における位置座標ベクトル $\mathbf{p}$ は、

$$\mathbf{p} = (x, y, z)^T$$

と書ける。位置座標ベクトルは、空間的に近い点のまとまりを判別するために使用する (3.4.3 項および 3.5.2 項参照)。また以下で述べるように、さらに周囲の点群の分布から法線方向を推定することで特徴量とすることができる。




図 2 立方体点群 (左) とその法線成分の法線空間での分布 (右)
Fig. 2 Point cloud of a cube (left) and its distribution of normal components (right).

加えて、周囲の点群の法線の分布を参照することによりその分散も特徴量とすることができる。

3.2.1 法線ベクトル

まず法線等を推定するためには注目する点の周囲の点群の 3 次元座標値を取得する必要があるが、近傍点を探索するために注目点からすべての点までの距離を計算することは極めて効率が悪い。そこで Kd 木 [22] のデータ構造を用いて近傍点探索を高速化する。

法線の推定には注目点の近傍の任意の半径 r_n 内の点群を利用し、以下に述べるように主成分分析により計算する。

近傍点の個数を N 、第 i 番目の近傍点の位置座標ベクトルを $\mathbf{p}_i$ 、 N 個の近傍点の重心の位置座標ベクトルを $\bar{\mathbf{p}}$ とすると、以下の分散共分散行列 $\mathbf{C}_p$ が得られる。

$$\mathbf{C}_p = \frac{1}{N} \sum_{i=1}^N (\mathbf{p}_i - \bar{\mathbf{p}})(\mathbf{p}_i - \bar{\mathbf{p}})^T$$

分散共分散行列 $\mathbf{C}_p$ の固有値を $\lambda_1, \lambda_2, \lambda_3$ ($\lambda_1 \geq \lambda_2 \geq \lambda_3$) とし、対応する規格化した固有ベクトルをそれぞれ $\mathbf{u}_1, \mathbf{u}_2, \mathbf{u}_3$ とすると、法線ベクトル $\mathbf{n}$ は、

$$\mathbf{n} = \mathbf{u}_3$$

となる。

以上の計算では法線ベクトルの方向について不定性が残るが、提案手法では以下の方法で法線ベクトルの方向を定める。3D スキャナから得られる形状測定データは一般的にポリゴン形式となっており、測定対象物のスキャナ側の面を表面として定義するため、表裏の情報がポリゴンの表裏の情報として形状測定データに含まれている。そこで上述の法線ベクトルの計算の際、形状測定データの持つ表裏の情報を参照することで法線ベクトルの方向を定める。

各点について法線ベクトルを計算すると、たとえば立方体点群の場合には図 2 (左) に示すようになる。また法線ベクトルの成分のみに着目し 3 次元空間 (法線空間と呼ぶことにする) 内にプロットすれば、図 2 (右) のように半径 1 の球面上に点群が分布する。

点群の密度にもよるが、図 3 に示すように近傍点探索の半径が過小な場合はノイズの影響が大きくなり法線のばら




図3 適切な近傍点半径（左）と過小な近傍点半径（右）

Fig. 3 An appropriate neighborhood radius (left) and a too small neighborhood radius (right).




図4 法線成分の注目点近傍における分散

Fig. 4 Variance of normal components.

つきが大きくなるので注意が必要である。

2平面で形成されるエッジ部分のように、位置連続で接続する曲面に対応する点群についての法線ベクトルを法線空間内にプロットすると、異なる位置にデータが集中する傾向がある。たとえば平面に対応する点群では法線空間内においては1点にデータが集中する傾向があるため、2平面が交わりエッジを形成するような点群の場合は法線空間内においてはデータが2点に集中する。その性質を利用し、法線ベクトルは位置連続で接続した曲面に対応する点群を分割するために使用する（3.4.1項および3.4.2項参照）。

3.2.2 法線ベクトル成分の分散

次に、注目点の近傍の点の持つ法線ベクトルの分散を計算することで特徴量とすることができる。図2（右）のように法線ベクトルの成分は単位球面上に分布するが、法線空間内において注目点の近傍の点を探索し、その分散を調べることで特徴量とする（図4）。

前節で法線ベクトルを計算した際と同様に、法線ベクトルの分散の計算には注目点の近傍の任意の半径 r_v 内の点群を利用し、主成分分析により計算する。近傍点の個数を N 、第 i 番目の近傍点の法線ベクトルを $\mathbf{n}_i$ 、 N 個の近傍点の法線空間における重心を $\bar{\mathbf{n}}$ とすると、以下の分散共分散行列 $\mathbf{C}_n$ が得られる。

$$\mathbf{C}_n = \frac{1}{N} \sum_{i=1}^N (\mathbf{n}_i - \bar{\mathbf{n}})(\mathbf{n}_i - \bar{\mathbf{n}})^T$$

分散共分散行列 $\mathbf{C}_n$ の固有値を v_1, v_2, v_3 ($v_1 \geq v_2 \geq v_3$) とすると、法線ベクトルの分散 $\mathbf{v}$ は、

$$\mathbf{v} = (v_1, v_2, v_3)^T$$

と書ける。 $\mathbf{v}$ を新たな特徴量ベクトルとし3次元空間（分散空間と呼ぶことにする）内にプロットすると、平面に対応する点群については分散空間内の原点付近にデータが集中する傾向がある。また、曲率が近い曲面に対応する点群

表1 ハイパーパラメータ一覧

Table 1 List of hyperparameters.

r_n		法線の計算のための近傍点半径
r_v		法線の分散成分の計算のための近傍点半径
h_1	N_1	VBGMM のクラスタ数の上限
	w_1	ノイズ除去のウェイト閾値
h_2	ε_2	DBSCAN の近傍点半径
	n_2	DBSCAN のクラスタ最小点数
h_3	ε_3	DBSCAN の近傍点半径
	n_3	DBSCAN のクラスタ最小点数
h_4	N_4	VBGMM のクラスタ数の上限
	w_4	ノイズ除去のウェイト閾値
h_5	ε_5	DBSCAN の近傍点半径
	n_5	DBSCAN のクラスタ最小点数

のデータは分散空間内で同じ位置に集中する傾向がある。そこで法線ベクトルの分散は接線連続で接続した曲面に対応する点群を分割するために使用する（3.5.1項参照）。

3.3 セグメンテーションアルゴリズム概要

リバースエンジニアリングで一般的に対象となるのは機械部品等であり、それらの多くは位置連続で接続する面と接線連続で接続した面から構成される。曲率連続で接続する曲面が含まれることは稀であるため、本研究でのセグメンテーションの対象は接線連続までとし、意匠面のように曲率連続の曲面群で構成されるようなセグメンテーション境界が判然としない形状は取り扱わない。

セグメンテーションアルゴリズムはセグメンテーション前の点群 P_0 およびハイパーパラメータのリスト h_1, h_2, h_3, h_4, h_5 （表1）を入力とし、点群 P_0 を分割することで要素数が N の点群のリスト $S = \{P_1, \dots, P_N\}$ を出力する。大まかな処理の流れとして、まず入力点群をエッジ部分のような位置連続の境界でセグメンテーションする。すると位置連続以上の滑らかな境界のみを持つ点群が残る。そこで次に各点群について接線連続の境界でセグメンテーションすることで、位置連続および接線連続の境界でセグメンテーションされた点群が得られる。位置連続の境界でのセグメンテーション方法の詳細は3.4節で述べる。接線連続の境界でのセグメンテーションの方法の詳細は3.5節で述べる。

このような処理手続きは以下の疑似コードのように表現できる。疑似コード内のVBGMMとDBSCANはそれぞれVBGMMとDBSCANによるクラスタリング処理を表している。それらの第1引数はクラスタリング対象の点群を、第2引数はクラスタリングに利用する特徴量ベクトルの種類を表しており、 $\mathbf{P}$ が位置座標ベクトル、 $\mathbf{N}$ が法線ベクトル、 $\mathbf{V}$ が法線ベクトルの分散を表している。第3引数はクラスタリングアルゴリズムのハイパーパラメータのリストである。VBGMMとDBSCANの出力はいずれも点群のリストである。

Input: $P_0, h_1, h_2, h_3, h_4, h_5$

Output: S

```

01:  $S \leftarrow \text{VBGMM}(P_0, \mathbf{N}, h_1)$  (3.4.1 項参照)
02:  $S \leftarrow \text{DBSCAN}(\bigcup_{P \in S} P, \mathbf{N}, h_2)$  (3.4.2 項参照)
03:  $S' \leftarrow \emptyset$ 
04: for each  $P \in S$  do
05:    $S' \leftarrow S' \cup \text{DBSCAN}(P, \mathbf{P}, h_3)$  (3.4.3 項参照)
06: end for
07:  $S \leftarrow S'$ 
08:  $S' \leftarrow \emptyset$ 
09: for each  $P \in S$  do
10:    $S' \leftarrow S' \cup \text{VBGMM}(P, \mathbf{V}, h_4)$  (3.5.1 項参照)
11: end for
12:  $S \leftarrow S'$ 
13:  $S' \leftarrow \emptyset$ 
14: for each  $P \in S$  do
15:    $S' \leftarrow S' \cup \text{DBSCAN}(P, \mathbf{P}, h_5)$  (3.5.2 項参照)
16: end for
17:  $S \leftarrow S'$ 
18: return  $S$ 

```

3.4 位置連続曲面に対応する点群のセグメンテーション

本節では位置連続で接続する曲面に対応する点群を、接線不連続な境界で分割するセグメンテーション手法について述べる。

3.4.1 法線成分の VBGMM によるクラスタリング

まず点群の法線成分のみに着目しクラスタリングを行う。クラスタリングアルゴリズムには VBGMM を用いる。

簡単な例として立方体点群 (図 2) について生成したクラスタをウェイト (クラスタに含まれる点群数の全点群数に対する割合) 順にソートすると、図 5 のようにノイズおよびエッジ部と、立方体面上に対応する 6 クラスタの点群




図 5 立方体点群の法線空間でのクラスタリング結果の各クラスタのウェイト

Fig. 5 Weights of each clusters of the result of clustering on normal components of a point cloud of a cube.

が判然とする。

ウェイトが w_1 以下のクラスタはエッジ部またはノイズと見なして除外する。これによりクラスタリングとノイズの除去を同時に実行できる。

3.4.2 法線成分の DBSCAN によるクラスタリング

VBGMM ではクラスタ形状を球状と仮定する。そのため法線成分の分布領域が広範囲にわたる点群については、前節での法線空間での VBGMM によるクラスタリングの結果、同一曲面に対応するはずの点群が別クラスタに分割されてしまうことがある (図 6)。

そこで次に法線空間で DBSCAN を実行することにより、別クラスタに分割されてしまったクラスタを統合する (図 7)。

3.4.3 位置座標成分の DBSCAN によるクラスタリング

点群の形状が非凸包の場合は、法線空間でのクラスタリングの結果、位置座標空間では明らかに別のクラスタに属する点群が、同一クラスタに併合されてしまうことがある (図 8)。

そこで次に、前節のクラスタリング処理の結果エッジ部とノイズが除外された点群に対して、位置座標空間において DBSCAN によるクラスタリングを行う。DBSCAN はクラスタ数の指定が不要であるのに加えてクラスタ形状が球状でなくとも適用可能である。これにより図 8 で法線空間では併合されてしまった点群が正しく別クラスタに分割される (図 9)。




図 6 曲面に対応する点群 (左) と法線空間の VBGMM によるクラスタリング結果 (右)

Fig. 6 A point cloud of a curved surface (left) and the result of clustering on normal components by VBGMM (right).




図 7 図 6 (右) で分割されてしまった点群に対する法線空間での DBSCAN によるクラスタリング結果

Fig. 7 The result of clustering on normal components by DBSCAN.




図 8 非凸包の点群 (左) と法線空間でのクラスタリング結果 (右)
Fig. 8 A point cloud of a concave hull (left) and the result of clustering on normal components (right).




図 9 座標空間での DBSCAN によるクラスタリング結果
Fig. 9 The result of clustering on position coordinates by DBSCAN.

本節で述べた処理は 3.3 節の疑似コードの 5 行目に該当する。すなわち、前節までの処理の結果として得られた点群のリスト S から各点群 P を取り出し、 P およびハイパーパラメータ h_3 を DBSCAN の入力とし、出力されたクラスタリング後の複数の点群を点群のリスト S' に追加する。

3.5 接線連続曲面に対応する点群のセグメンテーション

前節までの処理により位置連続で接続する曲面に対応する点群のセグメンテーションは可能であるが、接線連続で接続する曲面に対応する点群のセグメンテーションはできない。そこで本節では接線連続で接続する曲面に対応する点群を、曲率不連続な境界で分割するセグメンテーション手法について述べる。

3.5.1 法線の分散成分の VBGMM によるクラスタリング

図 10 (左) のような、接線連続で接続する曲面に対応する点群について 3.2.2 項で述べた法線成分の分散空間内でクラスタリングを行う。

図 11 のように、分散空間内ではデータは曲率が同一な曲面ごとに塊状にクラスタを形成していると考えられるので、クラスタリングアルゴリズムには VBGMM を用いる。ウェイトが w_4 以下のクラスタはノイズと見なして除外する。クラスタリングの結果として、図 10 (右) のように曲率の異なる点群が別クラスに分割される。

本節で述べた処理は 3.3 節の疑似コードの 10 行目に該当する。すなわち、前節までの処理の結果として得られた




図 10 接線連続で接続した点群 (左) と法線の分散空間での VBGMM によるクラスタリング結果 (右)
Fig. 10 A point cloud of a tangent continuous surface (left) and the result of clustering on variances of normal components by VBGMM (right).




図 11 図 10 の点群の法線の分散空間での分布
Fig. 11 The distribution of variances of normal components for data shown in Fig. 10.




図 12 接線連続で接続した点群の法線の分散空間での VBGMM によるクラスタリングの結果 (左) と位置座標空間での DBSCAN によるクラスタリング結果 (右)
Fig. 12 The result of clustering on variances of normal components for a point cloud of a tangent continuous surface by VBGMM (left) and the result of clustering on position coordinates by VBGMM (right).

点群のリスト S から各点群 P を取り出し、 P およびハイパーパラメータ h_4 を VBGMM の入力とし、出力されたクラスタリング後の複数の点群を点群のリスト S' に追加する。

3.5.2 位置座標成分の DBSCAN によるクラスタリング

法線の分散成分の VBGMM によるクラスタリングの結果、接線連続で接続する曲面に対応する点群は分割されるが、複数の接線連続曲面がひと続きになっているような場合に、位置連続でない点群が同じクラスに属したままとなる場合がある。そこでさらに位置座標空間内で DBSCAN によるクラスタリングを行うことで分割する (図 12)。

本節で述べた処理は 3.3 節の疑似コードの 15 行目に該

当する。すなわち、前節までの処理の結果として得られた点群のリスト S から各点群 P を取り出し、 P およびハイパーパラメータ h_5 を DBSCAN の入力とし、出力されたクラスタリング後の複数の点群を点群のリスト S' に追加する。

3.6 エッジ部の点群の扱い

点群のセグメンテーションに関する既存の研究では、エッジ部分を含めたすべての点をセグメンテーションの対象としている。しかし、実用的にはリバースエンジニアリングにおいてはエッジやフィレット部分等の細かな部分については点群から忠実に再現する必要はない場合が多い。むしろサーフェスを生成した段階ではサーフェス間にはフィレットがないほうがデータを扱いやすい。必要であればフィレット以外のサーフェスを生成後にフィレットを追加することは一般的には容易である。以上のことから、リバースエンジニアリングという目的に特化すれば、サーフェスを生成する段階でサーフェスどうしの連続性が保証されるのであれば、点群のセグメンテーションの段階ではエッジ部分の点群は除外してもさほど問題ではない。前節までの手法によるセグメンテーションの結果、ノイズ除去と同時にエッジ部分の点群は除外されるが、上述の理由によりリバースエンジニアリングの場合は問題にはならない。

4. 実験および結果

提案手法を用いていくつかの点群データについてセグメンテーションの実験を行った。使用した点群データについて表 2 にデータ名、点群数、セグメント数およびセグメンテーションの処理に要した時間を示した。ハイパーパラメータはデータごとに調整しており、表 3 に実験で使ったハイパーパラメータの値の一覧を示した。

4.1 実験の環境

前節で紹介した手法を、ウェブブラウザ上で実行可能なデータ分析ツールである Jupyter Notebook [23] 上で Python により実装した。実装するにあたり使用したライブラリは以下のとおりである。まず、多次元配列を用いた効率的な演算を実行するために NumPy [24] を、VBGMM や DBSCAN や主成分分析等の機械学習アルゴリズムを実行するために scikit-learn [25] を利用した。さらに、入力する点群データのファイル形式は一般的に STL 形式なの

で、STL ファイルのインポートのために numpy-stl [26] を利用した。加えて Kd 木を用いた近傍点探索アルゴリズム等の点群処理のために Open3D [27] を利用した。なお、実験に使用したノート PC の CPU は Intel Core i7-4510U (2.0 GHz) である。

4.2 Fandisk の点群データのセグメンテーション

点群のセグメンテーション手法に関する論文でよく用いられる代表的なデータである、Fandisk (図 13) の形状測定点群データに提案手法を適用した。

図 14 は (a)~(e) の順に、それぞれ 3.4.1, 3.4.2, 3.4.3, 3.5.1, 3.5.2 項で述べたクラスタリング手法を順に適用したセグメンテーション結果を示す。図 14 (a) の段階では同一曲面に属する点群が分割されてしまっているが、次の (b) の段階では同一クラスに併合されている。また (c) の段

表 3 実験で使ったハイパーパラメータ一覧

Table 3 List of hyperparameters used in our experiments.

データ名		Fandisk	非凸立方体	葉形
r_n		0.3	1.0	1.0
r_v		0.5	3.0	3.0
h_1	N_1	30	20	30
	w_1	0.0025	0.05	0.025
h_2	ε_2	0.015	0.2	0.2
	n_2	10	100	100
h_3	ε_3	1.0	3.0	3.0
	n_3	50	100	50
h_4	N_4	3	10	10
	w_4	0.1	0.05	0.025
h_5	ε_5	0.4	3.0	3.0
	n_5	10	100	50




図 13 Fandisk の前面 (左側) と背面 (右側) (STL データの曲率表示 (上段), セグメンテーション例 (下段))

Fig. 13 The front (left) and the back (right) of the Fandisk. STL data shown as curvature (upper) and an example of segmentation result (lower).

表 2 実験で使った点群データ

Table 2 Point clouds used in our experiments.

データ名	点群数	セグメント数	処理時間(min)
Fandisk	134299	22	20
非凸立方体	88779	9	3
葉形	71283	4	2




図 14 Fandisk の点群の各処理ステップにおけるセグメンテーション結果の前面（左側）と背面（右側）

Fig. 14 The Front (left side) and the back (right side) of the segmentation results of each steps for Fandisk.

階では同一クラスに併合されている接線連続の曲面に属する点群が、(d) の段階で曲率ごとに分割されている．最終的に (e) では位置連続でないクラスが別クラスに分割されている．

図 14(e) の最終的なセグメンテーション結果を、曲率に基づいて領域を色分けした図 13 下段のセグメンテーション例と比較すると、おおむね近いセグメンテーション結果となっているが、図 14(e) では曲率連続の曲面に対応する境界で点群が分割されずに同一の領域に併合されている．

4.3 実際の形状測定点群データのセグメンテーション

実物模型の形状を 3D スキャナで測定して得られた形状測定点群データに提案手法を適用し、セグメンテーションの実験を行った．使用したのは図 15（上）の非凸立方体




図 15 非凸立方体（左側）と葉形（右側）（模型の実物（上段）、形状測定データ（中段）、セグメンテーション結果（下段））

Fig. 15 A concave cube (left side) and a leaf shape (right side). Actual objects (upper), acquired point clouds (middle), and segmentation results (lower).

表 4 測定条件

Table 4 Measurement conditions.

実物模型	スケール(mm)	ショット数	測定時間(min)
非凸立方体	50×40×35	20	20
葉形	90×60×30	12	15

と葉形の模型の形状測定点群データである．測定に使用したスキャナ機器は Steinbichler の COMET6 で、測定範囲が 146 × 97 × 80 mm のレンズを使用した．測定条件は表 4 に示した．実際の形状測定データにはかなりのノイズとデータの欠損が含まれるため、たとえ平面に対応する点群であっても同一平面上には存在しない．にもかかわらず、ノイズのフィルタリング処理と穴埋め処理を施すことなく適切なセグメンテーション結果となった (図 15 (下))．図 15 の下段左側の非凸立方体のセグメンテーション結果で、面内部の点が部分的に欠落しているのはノイズとして除外されたためである．しかしリバースエンジニアリングでサーフェスを推定するうえでは影響はごく小さいため問題にはならない．

5. 考察

文献 [3] は 2.1 節で述べたように属性ベースの手法について言及している．属性ベースの手法はあらかじめ計算した点群内の各点の持つ何らかの属性に基づいて点群をグループ分けする．本研究の提案手法は位置座標値、法線成分、法線の分散をもとにクラスタリングする手法であるた




図 16 接線連続と曲率連続で接続したサーフェス。コムはエッジの曲率を示す

Fig. 16 A surface consisting of tangent and curvature continuous surfaces. The comb indicates the curvature of the edge.

め、属性ベースの手法に位置づけられる。

実験では、Fandisk および実際の形状測定点群データにも適切なセグメンテーション結果となり、特に実際の形状測定点群データではノイズや欠損の修正なしで適切なセグメンテーション結果となった。また Fandisk の実験では、文献 [5], [6] のようなエッジベースや領域ベースの手法では対応できなかった接線連続の境界でのセグメンテーションにも成功した。それゆえ Part based [9] ではなく CAD データにおけるサーフェス構成を意識したセグメンテーションが可能である。さらに提案手法は教師なし学習であるため深層学習を利用した手法とは異なり学習データを必要としない。

エッジ部分やノイズの点群が最終的に除外されたが、これはノイズを積極的に捨てていくというアルゴリズムのためである。それゆえ面積が他の部位と比較して小さく、点群数が相対的に少数となる面は完全に除外されてしまう場合があるので注意が必要だが、エッジ部分の点群は多少抜け落ちてもしリバースエンジニアリングにおけるサーフェス生成という目的の達成にはほぼ影響はない。

接線連続で接続する点群のセグメンテーションが可能であることを示すことができた一方で、提案手法では接線連続よりさらに滑らかな連続性である、曲率連続で接続する点群のセグメンテーションを行うことはできない。

たとえば、図 16 に示すサーフェスは 3 枚のサーフェスから構成されており、接線連続の境界と曲率連続の境界が混在する。それゆえ図 16 のサーフェスから生成した点群を提案手法でセグメンテーションすると、接線連続の境界では点群が分割されるが曲率連続の境界では点群が分割されない (図 17)。

曲率連続で接続する点群のセグメンテーションのためには法線の分散の微分量を利用する必要があるが、ノイズの影響が大きくなると予想される。

また提案手法ではクラスタリングアルゴリズムのハイパーパラメータ設定を手動で行う必要がある。ハイパーパ




図 17 図 16 のサーフェスから生成した点群 (左) と分散空間での VBGM によるクラスタリング結果 (右)

Fig. 17 A point cloud generated from surface shown in Fig. 16 (left) and the result of clustering on variances of normal components by VBGM (right).

ラメータ設定を自動化できれば、点群の密度やノイズの程度によらずいかなる点群にも対応可能になると予想される。

6. おわりに

リバースエンジニアリングという目的に特化し、点群の位置座標成分、法線成分、法線成分の分散を特徴量とし、VBGM によるクラスタリングと DBSCAN によるクラスタリングをあわせて適用することで、位置連続および接線連続で接続した曲面に対応する点群のセグメンテーションを自動化する手法を考案した。

有名な Fandisk の点群データおよび非凸立方体と葉形の模型の形状測定点群データに対して提案手法によりセグメンテーションの実験を行ったところ、適切なセグメンテーション結果が得られた。

今後は今回使用した Fandisk のような、より複雑な形状のサンプルについての実際の形状測定点群データに対して提案手法を適用し、その有効性を確認するとともに、クラスタリングアルゴリズムのハイパーパラメータの探索の自動化の手法を検討したい。

参考文献

- [1] 松田優也, 小高知宏: 機械学習を用いたリバースエンジニアリングのための形状測定点群データのセグメンテーション, 第 82 回全国大会講演論文集 (2020).
- [2] 松田優也, 小高知宏: 機械学習を用いたリバースエンジニアリングのための形状測定点群データのセグメンテーション, 研究報告オーディオビジュアル複合情報処理 (AVM) (2020).
- [3] Nguyen, A. et al.: 3D point cloud segmentation – A Survey, *6th IEEE conference on robotics, automation and mechatronics (RAM)*, pp.225–230 (2013).
- [4] Gumhold, S. et al.: Feature Extraction from Point Clouds, *Proc. 10th IMR*, pp.293–305 (2001).
- [5] Méritot, Q. et al.: Voronoi-Based Curvature and Feature Estimation from Point Clouds, *IEEE Trans. Visualization and Computer Graphics*, Vol.17, No.6, pp.743–756 (2010).
- [6] Rabbani, T. et al.: Segmentation of point clouds using smoothness constraint, *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol.36, No.5, pp.248–253 (2006).

- [7] Schnabel, R. et al.: Efficient RANSAC for Point-Cloud Shape Detection, *Computer Graphics Forum*, Vol.26, No.2, pp.214–226 (2007).
- [8] Golovinskiy, A. et al.: Min-cut based segmentation of point clouds, *Proc. IEEE Workshop on Search in 3D and Video at ICCV*, pp.39–46 (2009).
- [9] Rodrigues, R.S. et al.: Part-based mesh segmentation: A survey, *Computer Graphics Forum*, Vol.37, No.6, pp.235–274 (2018).
- [10] Yamakawa, S. et al.: Feature Edge Extraction Via Angle-Based Edge Collapsing and Recovery, *Journal of Computing and Information Science in Engineering*, Vol.18, No.2 (2018).
- [11] Mejia, D. et al.: Hybrid geometry/topology based mesh segmentation for reverse engineering, *Computers & Graphics*, Vol.73, pp.47–58 (2018).
- [12] Van Biesbroeck, A. et al.: CAD Model Segmentation Via Deep Learning, *International Journal of Computational Methods*, 2041005 (2020).
- [13] Muraleedharan, L.P. et al.: Autoencoder-based part clustering for part-in-whole retrieval of CAD models, *Computers & Graphics*, Vol.81, pp.41–51 (2019).
- [14] Le, T. et al.: Pointgrid: A deep network for 3D shape understanding, *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp.9204–9214 (2018).
- [15] Qi, C.R. et al.: Pointnet: Deep learning on point sets for 3D classification and segmentation, *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp.652–660 (2017).
- [16] Qi, C.R. et al.: Pointnet++: Deep hierarchical feature learning on point sets in a metric space, *Advances in Neural Information Processing Systems*, pp.5099–5108 (2017).
- [17] Geomagic Design X, available from (<https://ja.3dsystems.com/software/geomagic-design-x/features>) (accessed 2020-01-27).
- [18] Varady, T.: Automatic procedures to create cad models from measured data, *Computer Aided Design and Application*, Vol.5, No.5, pp.577–588 (2008).
- [19] MacQueen, J.: Some Methods for Classification and Analysis of Multivariate Observations, *Proc. 5th Berkeley Symposium on Math*, Vol.1, pp.281–296 (1967).
- [20] Bishop, C.M.: *Pattern Recognition and Machine Learning*, Springer (2006).
- [21] Ester, M. et al.: A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise, *Proc. KDD-96*, pp.226–231 (1996).
- [22] Bentley, J.L.: Multidimensional binary search trees used for associative searching, *Comm. ACM*, Vol.18, No.9, pp.509–517 (1975).
- [23] Jupyter Notebook, available from (<https://jupyter.org/>) (accessed 2020-01-27).
- [24] NumPy, available from (<https://numpy.org/>) (accessed 2020-01-27).
- [25] scikit-learn, available from (<https://scikit-learn.org/stable/>) (accessed 2020-01-27).
- [26] numpy-stl, available from (<https://pypi.org/project/numpy-stl/>) (accessed 2020-01-27).
- [27] Open3D, available from (<http://www.open3d.org/>) (accessed 2020-01-27).



松田 優也 (正会員)

2006 年東京大学理学部地球惑星物理学専攻卒業。2008 年同大学大学院理学系研究科地球惑星科学専攻修士課程修了。同年株式会社アルモニコス入社。2013 年より現在まで福井県工業技術センターに勤務。主に 3 次元形状処理、機械学習の研究に従事。



小高 知宏 (正会員)

1990 年早稲田大学大学院理工学研究科博士後期課程修了。博士（工学）。1990 年九州大学医学部附属病院助手。1993 年福井大学工学部情報工学科助教授。2004 年福井大学大学院工学研究科教授。現在に至る。機械学習、ネットワークセキュリティ、教育工学等の研究に従事。