



Title	CAEモデル自動生成のための離散的形状表現を活用した三次元特徴形状認識技術の開発
Author(s)	高嶋, 英蔵
Degree Grantor	北海道大学
Degree Name	博士(情報科学)
Dissertation Number	甲第14751号
Issue Date	2021-12-24
DOI	https://doi.org/10.14943/doctoral.k14751
Doc URL	https://hdl.handle.net/2115/83917
Type	doctoral thesis
File Information	Takashima_Hideyoshi_220125.pdf



**C A E モデル自動生成のための
離散的形状表現を活用した
三次元特徴形状認識技術の開発**

高嶋 英巖

北海道大学 大学院情報科学研究科

システム情報科学専攻

2021 年 11 月

本論文は北海道大学大学院情報科学研究科の
博士（情報科学）授与の要件として提出した博士論文である。

高嶋 英巖

審査委員： 主査 金井 理 教授
副査 小野里 雅彦 教授
伊達 宏昭 准教授

CAEモデル自動生成のための 離散的形状表現を活用した 三次元特徴形状認識技術の開発*

高嶋 英巖

概要

自動車業界では、世界共通の重要課題である気候変動への対策として、電動車両の開発を強力に推し進めている。この技術革新において、デジタル開発技術は、品質保証、開発期間短縮、コスト低減を実現する重要な役割を担っており、特に、高精度に性能を予測できる大規模 CAE は、製品開発に必要不可欠である。一方で、大規模 CAE モデルの作成工数は、仕様の詳細化に伴い大きく増加しており、特に、大規模 CAE モデルの根幹を成す FE メッシュの作成は、プロセス全体のボトルネックとなっている。これは、現在の商用 CAE ソフトウェアに、仕様に適合した FE メッシュを完全自動で作成できる機能がなく、未だエンジニアの判断と手作業に依存しているためである。仕様に適合した FE メッシュの生成手順は、特徴形状の発見、その特徴形状の局所特徴領域の抽出、そして、その部位に規定された仕様に基づく FE メッシュの分割であり、特に、特徴形状及び局所特徴領域の認識には多くの労力が必要とされ、自動化が強く求められている。しかし、従来の特徴形状認識手法は、Product Data Quality (PDQ) 劣化部を含む CAD モデルや、複雑で滑らかな曲面で構成された特徴形状を含む CAD モデル上における特徴形状認識が困難であり、また、特徴形状タイプ毎に ad hoc な処理アルゴリズムの実装が必要なためアルゴリズムの統一性と拡張性に欠けるという問題がある。さらに、認識結果を後工程の FE メッシュ自動生成に利用する手段が議

論されていないため、システム化が困難である。本研究では、これらの問題を解決し、CAEモデル自動生成システムを実現するため、離散的形状表現を活用した特徴形状認識技術を新たに提案する。具体的には、FEメッシュ生成方式に応じて、三次元点群と形状記述子を用いた類似特徴形状認識技術、及び三次元点群と深層学習を用いた自由曲面特徴形状認識技術の2つからなる特徴形状認識技術を開発した。前者は、データベース上の参照特徴形状を用いて入力CADモデル上の類似特徴形状を発見する技術であり、形状記述子とRANSACを用いて射影変換行列を推定し、類似特徴形状を特定する。後者は、点群深層学習アプローチにより、入力CADモデル上から、予め学習させた特徴形状及び局所特徴領域を抽出する技術であり、Multi-scale bounding boxとNon-maximum suppressionを組み合わせた手法により、単体特徴形状のみでトレーニングした深層学習ネットワークを用いて、製品又は部品CADモデルの全体形状内に存在する特徴形状を認識する。また、単体特徴形状でトレーニングする深層学習ネットワークを用いることで、単体特徴形状CADモデルで構成されるトレーニングデータセットを、パラメトリックCADを用いて、形状パラメータから容易に生成することを可能にした。本研究で提案した2つの特徴形状認識手法について、複数のモデルを用いた検証実験により有効性を示した。さらに、提案手法による特徴形状認識結果を用いて、特徴形状認識から仕様適合FEメッシュ生成までの一連の処理プロセスの自動化に関する基礎実験を行い、これら一連の処理プロセスを含むCAEモデル自動生成システムの実現性を示した。

キーワード：大規模 CAE モデル， FE メッシュ， 三次元点群， 形状記述子， 点群深層学習， データ拡張， 製品開発

*北海道大学大学院情報科学研究科システム情報科学専攻，博士論文，SSI-DT79165030，
2021年11月18日

Development of 3D feature recognition method utilizing discrete shape representations for automatic CAE model generation[†]

Takashima, Hideyoshi

Abstract

The automobile industry has strongly promoted to develop the electric vehicle as a countermeasure against climate change, a vital issue common globally. In this technological innovation, digital development technology plays an important role in quality assurance, development period shortening, and cost reduction. In particular, large-scale CAE is one of the indispensable digital development technology. However, on the other hand, the person-hours for generating large-scale CAE models have increased significantly as the specifications refinement. Especially, the generation of the FE mesh, an essential part of the large-scale CAE model, is a bottleneck in the entire CAE model generation process. This bottleneck is because the automatic feature-compliant FE meshing for CAD models is not fully supported in commercial CAE software, requiring a great deal of operation rely only on the engineer's decisions and manual operations. The procedure for generating FE mesh comply with specifications is mainly of a series of the following operations: first, extracting feature shapes from a given CAD model, then, performing segmentation of each feature shape into

local areas, finally, generating FE mesh that complies with specific meshing rules defined by recognized feature shapes and areas. 1st and 2nd of this procedure, that is, feature shape recognition, are complex for manual operation. Therefore, automation is strongly required. However, current feature-extraction techniques from CAD models to generate FE mesh, the following issues still exist. First, the feature-extraction algorithm does not work robustly when the CAD models have PDQ issues. Second, the free-form features surrounded by complicated and smooth boundaries are challenging to detect when using these techniques. Third, it is necessary to design the extraction algorithm ad hoc way to extract different feature types with similar shapes. Fourth, it is difficult to system since there is no discussion of using recognition results to FE mesh generation. In this study, to solve these issues and realize an automatic CAE model generation system, we proposed a new feature shape recognition method that utilizes discrete shape representation. According to a type of FE mesh generation way, we have developed a similar feature shape recognition method using point cloud and shape descriptor and a free-form feature shape recognition method using point cloud and deep learning. The former is a method for extracting similar feature shapes on the input CAD model using the reference feature shape on the database. It estimates the projective transformation matrix using the shape descriptor and RANSAC to identify the similar feature shape. The latter is a method for extracting feature shapes and local feature areas on an input CAD model using a point cloud deep learning approach. An approach that combines a multi-scale bounding box and non-maximum suppression enables recognizing feature shape using a deep neural network trained with a single feature shape. Additionally, this approach made it possible to generate many single feature shape CAD

models from shape parameters using parametric CAD modeling and use them as the training dataset. At last, experiments using multiple verification models showed the effectiveness of the two feature shape recognition methods proposed in this study. Furthermore, basic FE mesh generation experiments using the proposed method's feature shape recognition results showed the feasibility of an automatic CAE model generation system.

Key words: Large-scale CAE model, FE mesh, Point cloud, Shape descriptor, Point cloud deep learning, Data augmentation, Product development

† Doctor candidate's Thesis, Division of Systems and Information Engineering, Graduate School of Information Science and Technology, Hokkaido University, SSI-DT79165030, Nov. 18th, 2021.

目次

C A E モデル自動生成のための離散的形状表現を活用した三次元特徴形状認識技術の開発	i
Development of 3D feature recognition method utilizing discrete shape representations for automatic CAE model generation	iii
目次	vi
図目次	x
表目次	xv
第 1 章 緒論	
1-1 研究背景	1
1-2 関連研究	7
1-2-1 CAD/CAM における形状特徴認識	7
1-2-2 部分形状認識	16
1-2-3 三次元物体認識	22
1-3 本研究の目的と特徴	27
1-3-1 従来手法の問題点	27
1-3-2 本研究の目的	28
1-3-3 手法及びその特徴	28
1-4 本論文の構成	35

第 2 章 三次元点群と形状記述子を用いた類似特徴形状認識技術の開発

2-1	特徴とアルゴリズムの概要	37
2-2	アルゴリズムの詳細	40
2-2-1	STEP1：CAD モデル表面上の三次元点群生成	40
2-2-2	STEP2：局所形状記述子の生成	42
2-2-3	STEP3：キーポイントの選択	45
2-2-4	STEP4：類似キーポイントペアセットの作成	47
2-2-5	STEP5：近接する類似キーポイントのクラスタ化	48
2-2-6	STEP6：RANSAC による類似特徴形状抽出	49
2-3	検証実験	53
2-3-1	検証実験①：単体の類似特徴形状の抽出実験	53
2-3-2	検証実験②：互いに独立して配置された複数の類似特徴形状の抽出実験	55
2-3-3	検証実験③：滑らかに接続された単体の類似特徴形状の抽出実験	60
2-3-4	検証実験④：滑らかに接続された複数の類似特徴形状の抽出実験	62
2-4	まとめと今後の課題	66

第 3 章 三次元点群と深層学習を用いた自由曲面特徴形状認識技術の開発

3-1	特徴とアルゴリズムの概要	69
3-2	アルゴリズムの詳細	71
3-2-1	STEP1：パラメトリック CAD による特徴形状 CAD モデルの生成	71

3-2-2	STEP2：三角形メッシュの生成	72
3-2-3	STEP3：特徴形状点群トレーニングデータセットの生成	73
3-2-4	STEP4：深層学習ネットワークのトレーニング	74
3-2-5	STEP5：入力 CAD モデル上の特徴形状候補領域の抽出	76
3-2-6	STEP6：特徴形状領域の検出と特徴形状クラスの設定	79
3-2-7	STEP7：局所特徴領域のラベル割当て	80
3-3	検証実験	82
3-3-1	検証実験①：単体の特徴形状の認識実験	82
3-3-2	検証実験②：互いに独立して配置された特徴形状の認識実験	84
3-3-3	検証実験③：滑らかに接続された特徴形状の認識実験	86
3-3-4	検証実験④：学習ネットワーク及びデータセットの違いによる 比較検証	89
3-3-5	検証実験⑤：手法 1 の検証モデルによる認識実験	93
3-4	まとめと今後の課題	96

第 4 章 認識特徴形状に基づく FE メッシュ自動生成と提案手法の有効性検証

4-1	手法 1 の特徴形状認識結果に基づくマッピング方式 FE メッシュ自動生成	100
4-2	手法 2 による特徴形状認識結果に基づく作成手順逐次実行方式 FE メッシュ自動生成	104
4-3	仕様適合 FE メッシュによる構造解析	108
4-4	PDQ 劣化部を含む CAD モデルを用いた FE メッシュ生成	110
4-5	まとめと今後の課題	113

第 5 章 結論と今後の課題	
5-1 結論	115
5-2 今後の課題	119
参考文献	120
謝辞	129
研究業績	131

図目次

図 1-1-1	仕様適合 FE メッシュの作成手順	3
図 1-1-2	その他の特徴形状の例	4
図 1-1-3	マッピング方式 FE メッシュ自動生成	5
図 1-1-4	作成手順逐次実行方式 FE メッシュ自動生成	6
図 1-2-1	加工形状特徴の一例	7
図 1-2-2	滑らかな曲面で構成された特徴形状	8
図 1-2-3	三角形メッシュを用いた滑らかな曲面の特徴形状認識手法	8
図 1-2-4	三角形メッシュを用いた加工形状特徴認識手法	9
図 1-2-5	Heat Kernel Signature (HKS) による特徴形状抽出手法	10
図 1-2-6	FE メッシュ自動生成のためのグラフベースボリューム分割手法	11
図 1-2-7	FE メッシュ自動生成のためのルールベース特徴形状認識手法	12
図 1-2-8	六面体 FE メッシュ自動生成のためのスweep形状ボリューム分割手法	12
図 1-2-9	六面体 FE メッシュ自動生成のためのボリューム分割手法	13
図 1-2-10	滑らかな曲面で構成される特徴形状に対応可能な FE メッシュ生成手法の一例	14
図 1-2-11	三次元畳み込みニューラルネットワークに基づく加工形状特徴認識手法	15
図 1-2-12	3D メッシュによる部分全体形状マッチング手法	17
図 1-2-13	Fast Reject スキーマによる部分全体形状マッチング	17

図 1-2-14	部分全体形状マッチングに基づく土木構造物の 3D モデル再構成システム	18
図 1-2-15	FE メッシュ自動生成のためのグラフベース類似部分形状検索手法	19
図 1-2-16	三次元点群深層学習ネットワーク PointNet++	21
図 1-2-17	形状分布記述子によるオブジェクトの類似性評価	22
図 1-2-18	PFH 形状記述子及び FPFH 形状記述子	23
図 1-2-19	PFH 及び TH に基づく機械学習アプローチによる形状分類手法	24
図 1-2-20	SHOT 形状記述子	25
図 1-2-21	PPF 形状記述子	25
図 1-2-22	SI 形状記述子によるポリープ検出の一例	26
図 1-3-1	従来手法の問題点	28
図 1-3-2	離散的形状表現を活用した特徴形状認識手法	29
図 1-3-3	三次元点群と形状記述子を用いた類似特徴形状認識技術の研究スコープ	31
図 1-3-4	三次元点群と深層学習を用いた自由曲面特徴形状認識技術の研究スコープ	32
図 2-1-1	三次元点群と形状記述子を用いた類似特徴形状認識技術のアルゴリズムの概要	39
図 2-2-1	三次元点群の生成	40
図 2-2-2	局所形状特徴量の計算	43
図 2-2-3	Shape Index の値と形状タイプ	44
図 2-2-4	SHOT におけるサポート球の分割領域と内積値投票ビン	44
図 2-2-5	マルチスケール・サポート球による SHOT 特徴量	45

図 2-2-6	キーポイントの選択	46
図 2-2-7	類似キーポイントペアセットの作成	47
図 2-2-8	近接類似キーポイントペアクラスタセットの作成	48
図 2-2-9	RANSAC による類似特徴形状抽出アルゴリズム	49
図 2-3-1	検証実験①：検証用モデル	54
図 2-3-2	検証実験①：特徴形状抽出結果	54
図 2-3-3	検証実験②：検証用モデル	56
図 2-3-4	SI による判定閾値の調整	57
図 2-3-5	検証実験②：リブ形状による特徴形状抽出結果	58
図 2-3-6	検証実験②：ボス形状による特徴形状抽出結果	58
図 2-3-7	検証実験②：抽出できなかったボス形状	59
図 2-3-8	検証実験③：検証用モデル	61
図 2-3-9	検証実験③：特徴形状抽出結果	61
図 2-3-10	検証実験④：検証用モデル	63
図 2-3-11	検証実験④：特徴形状抽出結果	63
図 2-3-12	検証実験④：抽出できていない特徴形状	64
図 3-1-1	三次元点群と深層学習を用いた自由曲面特徴形状認識技術のアル ゴリズムの概要	70
図 3-2-1	特徴形状 CAD モデルデータセットの生成	72
図 3-2-2	三角形メッシュデータセットの生成	73
図 3-2-3	特徴形状点群トレーニングデータセットの生成	74
図 3-2-4	PointNet++ に基づく深層学習ネットワークのトレーニング	75
図 3-2-5	本手法における PointNet++ の活用方法（後半処理の概要）	76

図 3-2-6	入力 CAD モデル上の特徴形状候補領域の抽出	77
図 3-2-7	Multi-Scale Bounding Box (MSBB)	78
図 3-2-8	微形状領域の検出と特徴形状クラスの特定	79
図 3-2-9	Non-Maximum Suppression (NMS) による最大推定確率領域 の検出	80
図 3-2-10	点群サブセットにおける各ポイントの局所特徴領域推定確率の 算出	80
図 3-2-11	競合ポイントのラベル割当て	81
図 3-3-1	検証用の特徴形状 CAD モデルデータセットの形状バリエーショ ン	83
図 3-3-2	入力 CAD モデルの特徴形状クラス及び局所特徴領域ラベル	83
図 3-3-3	検証実験①：単体のリブとボスの認識結果	84
図 3-3-4	検証実験②：検証用入力 CAD モデル (モデル A)	85
図 3-3-5	検証実験②：モデル A の認識結果	85
図 3-3-6	検証実験③：検証用入力 CAD モデル (モデル B, C)	86
図 3-3-7	検証実験③：検証用入力 CAD モデル (モデル D, E)	87
図 3-3-8	検証実験③：モデル B の認識結果	87
図 3-3-9	検証実験③：モデル C の認識結果	88
図 3-3-10	検証実験③：モデル B の認識結果 (認識精度の劣化部)	88
図 3-3-11	検証実験③：モデル D と E の認識結果	89
図 3-3-12	検証実験④：検証モデル (モデル A, B, C)	91
図 3-3-13	検証実験⑤：検証モデルとトレーニングデータ	93
図 3-3-14	検証実験⑤：手法 1 の検証モデルによる認識結果	94

図 3-3-15	検証実験⑤：手法 1 の検証モデルによる認識結果（認識精度の劣化部）	94
図 4-1-1	検証実験②の認識結果に基づく FE メッシュマッピング結果	101
図 4-1-2	検証実験③の認識結果に基づく FE メッシュマッピング結果	101
図 4-1-3	参照特徴形状バリエーションを拡張した場合の FE メッシュマッピング結果（検証実験②モデル）	102
図 4-1-4	参照特徴形状バリエーションを拡張した場合の FE メッシュマッピング結果（検証実験③④モデル）	103
図 4-2-1	CAD モデルへのラベル割付け結果（モデル A）	105
図 4-2-2	CAD モデルへのラベル割付け結果（モデル B）	105
図 4-2-3	CAD モデルへのラベル割付け結果（モデル C）	106
図 4-2-4	FE メッシュ生成の結果	107
図 4-3-1	解析条件	108
図 4-3-2	構造解析結果	109
図 4-4-1	PDQ 劣化部を含む検証用 CAD モデル	110
図 4-4-2	PDQ 劣化部を含む CAD モデルに対する商用 CAE プリソフトウェア標準機能による FE メッシュ生成	111
図 4-4-3	PDQ 劣化部を含む CAD モデルに対する手法 2 による作成手順逐次実行方式 FE メッシュ自動生成	111

表目次

表 1-3-1	手法 1 及び手法 2 の概要	34
表 2-3-1	検証実験①：パラメータ設定情報	55
表 2-3-2	検証実験②：パラメータ設定情報（リブ）	59
表 2-3-3	検証実験②：パラメータ設定情報（ボス）	60
表 2-3-4	検証実験③：パラメータ設定情報	62
表 2-3-5	検証実験④：パラメータ設定情報	64
表 2-3-6	処理時間	65
表 3-3-1	検証実験④：比較検証結果	91
表 3-3-2	モデル G の処理時間	95

第 1 章

緒論

1-1 研究背景

自動車業界では、電動車両（Electric Vehicle, EV）への移行が強力に推し進められている。気候変動への対応は、世界共通の重要課題として、Sustainable Development Goals (SDGs)にも Goal 13 として掲げられ、日本では、2050 年までに温室効果ガスの排出を全体としてゼロにする、2050 年カーボンニュートラルの実現（第二百三回国会 菅内閣総理大臣所信表明演説）を目指している。EV 化により温室効果ガスである二酸化炭素（CO₂）の排出量を削減するには、発電所等による発電時の CO₂ 排出量の削減と、EV の消費電力あたりの走行距離（電費）の向上が重要であり、特に後者には、車両質量の影響が大きく、内燃機関（Internal Combustion Engine, ICE）車両の場合と同様に軽量化が必須となる。たとえば、バッテリーで駆動する EV（Battery Electric Vehicle, BEV）では、車両質量に占めるバッテリー質量の割合が大きく、軽量化は大きな課題となっている。しかし、ICE 車両と EV とでは、車両構造が異なるため、開発ノウハウの全てを共有することができず、開発工数を増大させている。このような開発工数の増大は、EV 化の他、自動運転技術の開発など急激な技術革新を迫られる自動車業界において解決すべき重要な課題の一つとなっている。

Computer-aided design (CAD), Computer-aided manufacturing (CAM), Computer-aided engineering (CAE) に代表されるデジタル開発技術は、品質保証、開発期間短縮、コスト低減に対する強力な手段として開発手法を変革し、開発の質を上げ、開発工数を大幅に削減してきた。前述した自動車業界に求められる技術革新を推進するうえで、デジタル開発技術の活用は必須

であり、そのため、デジタル開発技術の利用そのものに必要となる工数の増大は、優先して解決しなければならない重要な課題である。たとえば、多くのコストと期間のかかる試作実験を削減し、短期間で多くのトライ&エラーを可能にした衝突安全性能評価シミュレーションに代表される大規模 CAE においては、CAE モデルを精密に作り込むことで進化し、益々複雑な実現象を高い精度で予測できるようになっている。しかし、同時に、複雑且つ膨大な仕様によって、CAE モデルの作成難易度が高くなり、作成に要する工数が増加している。

CAE モデルとは、数値解析により物理現象を再現するシミュレーションソルバーの入力データのことであり、荷重や初速度などの解析条件、応力ひずみ曲線やひずみ速度依存性などの材料物性値、数値計算解法や計算パラメータなどの数値解析条件、そして、シミュレーションで対象とする形状や空間を再現する有限要素 (FE メッシュ)、及びボルトやスポット溶接などの結合要素により構成されており、自動車メーカーでは、上記のような CAE モデルを構成する様々な要素の定義に対して詳細な仕様を規定している。

大規模 CAE モデルの仕様は、各メーカーの設計思想や過去の経験を基にした性能評価において、実機との相関を取ることで定義され、シミュレーションにおける数値解析的な安定性と物理現象の再現性を保証し、デジタル性能評価を確実なものにしている。特に、大規模 CAE モデルの根幹を成す有限要素 (FE) メッシュの仕様は、要素の種類、粗密、パターン、サイズ、節点の配置などが、リブやボスなどの製品形状上の三次元特徴形状ごとに厳密に定義されており、CAE モデル仕様の中でも最も重要な仕様の 1 つである。たとえば、図 1-1-1 に示すように、円柱形の特徴形状であるボスの上面部に対する FE メッシュの仕様例としては、「中心軸から同心円状に、指定した数で節点を均等配置しなければならない」などが、各メーカーの性能評価基準に基づいて規定されている。

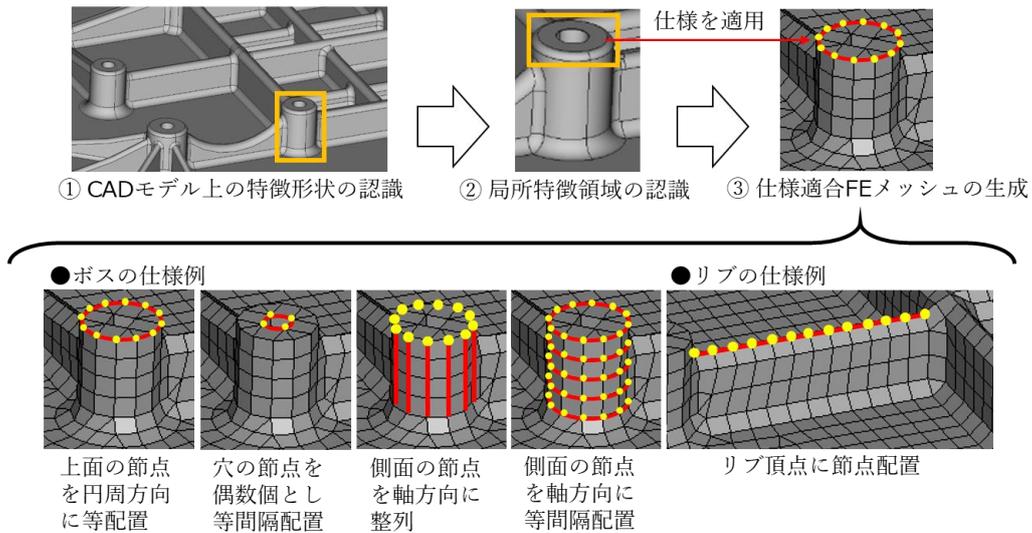


図 1-1-1 仕様適合 FE メッシュの作成手順

ボスやリブなどの特徴形状は、高強度の製品を軽量に実現するための、製品又は部品の局所機能構造である。局所的な荷重伝達を担うため、シミュレーション上においても高精度に荷重伝達を再現する必要がある。したがって、実機相関の取れた FE メッシュ仕様が必要であり、また、構造検討過程で得られる他のシミュレーション結果などとの比較を可能にするため、同一製品開発内又はメーカー社内において統一された共通の FE メッシュ仕様の適用が必要である。FE メッシュの各要素が仕様通りに配置されていなければ、シミュレーションの結果評価における精度が確保されず、過剰な対策や致命的な設計不具合を引き起こす可能性がある。この状況を回避するために、各メーカーでは、リブやボスに限らず、図 1-1-2 に示すエンボス、ヘミング、ジョグルなどの特徴形状ごとに、要素の種類、粗密、パターン、サイズ、節点の配置など、自社の性能評価基準に基づく独自の FE メッシュ仕様を定義している。このように、製品構造の一部として重要な役割を担う特徴形状は、製品 CAD モデル上の局所的な領域として定義することができ、また、それぞれの特徴形状に対し、各メーカーの性能評価基準や設計基準に基づいて、詳細な FE メッシュ仕様が規定されている。



図 1-1-2 その他の特徴形状の例

規定された仕様に適合する FE メッシュを作成する工程は、CAE モデル作成プロセス全体の中で最も作業工数が多い工程であり、自動化による工数削減及び期間短縮の効果が最も高い工程である。図 1-1-1 に示すように、一般的には、以下の手順で仕様適合 FE メッシュが作成される。

仕様適合 FE メッシュの作成手順

1. CAD モデル上からリブやボスなどの特徴形状を認識する。
2. 各特徴形状の上面部、側面部、穴部など、特徴形状上の局所特徴領域を認識する。
3. 認識された特徴形状と局所特徴領域の情報を基に、CAE プリソフトウェアを用いて、規定された仕様に適合する FE メッシュを生成する。

しかし、上記の手順 1 及び 2 の形状認識は、未だエンジニアによる判断と手作業に依存しており、特に CAD モデルの規模が大きく且つ形状が複雑な場合は、膨大な作業期間と工数が必要になる。また、複雑且つ膨大な作業による高いストレスにより、エンジニアのミスを誘発しやすい。一方で、手順 3 の FE メッシュ生成は、CAD モデル上の特徴形状及びその局所特徴領域を認識できていれば、多くのケースにおいて、既存の FE メッシュ生成技術を用いて自動処理が可能である。

現在の商用 CAE プリソフトウェアには、このような形状認識を含む仕様適

合 FE メッシュ自動生成機能が実装されていないため、デジタル性能評価プロセスの総工数に対する CAE モデル作成工数の割合が高く自動化の効果が見込めるにも関わらず、改善が困難な状況にある。そのため、CAE モデル作成の中で最も工数を必要とする FE メッシュ生成の自動化を目的とした、特徴形状とその局所特徴領域の自動認識技術の開発が強く求められている。

以上の考察から、各特徴形状の仕様に適合した FE メッシュ生成の自動化を実現する方法として、以下の 2 つの方法が有効であると考えられる。

(1) マッピング方式 FE メッシュ自動生成 (図 1-1-3)

データベースに登録された参照特徴形状に類似する特徴形状を、入力 CAD モデル上に発見し、それらの変換関係式を出力する。その変換関係式により、参照特徴形状に対して生成された FE メッシュを変形し、入力 CAD モデル上にコピーする方式。

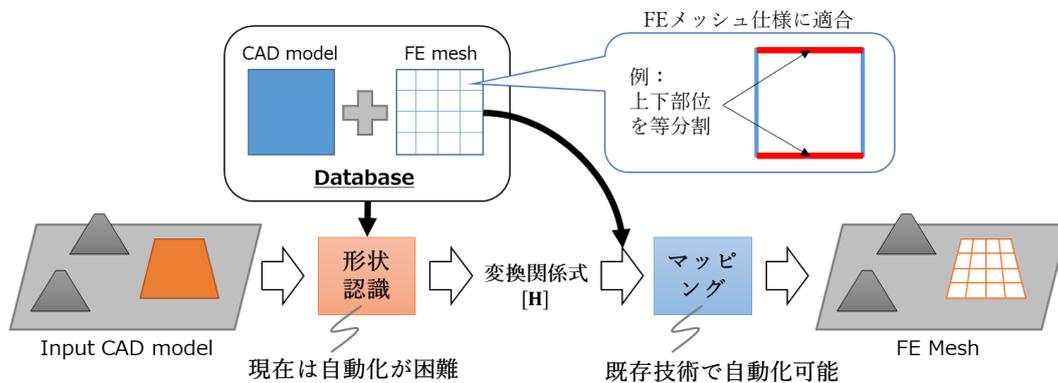


図 1-1-3 マッピング方式 FE メッシュ自動生成

(2) 作成手順逐次実行方式 FE メッシュ自動生成 (図 1-1-4)

入力 CAD モデル上の特徴形状とその局所特徴領域を認識し、ラベル付きモデルを出力する。それらの情報に基づき、仕様適合 FE メッシュの作成手順を、商用 CAE プリソフトウェアのマクロ機能を用いて逐次自動実行し生成する方式。

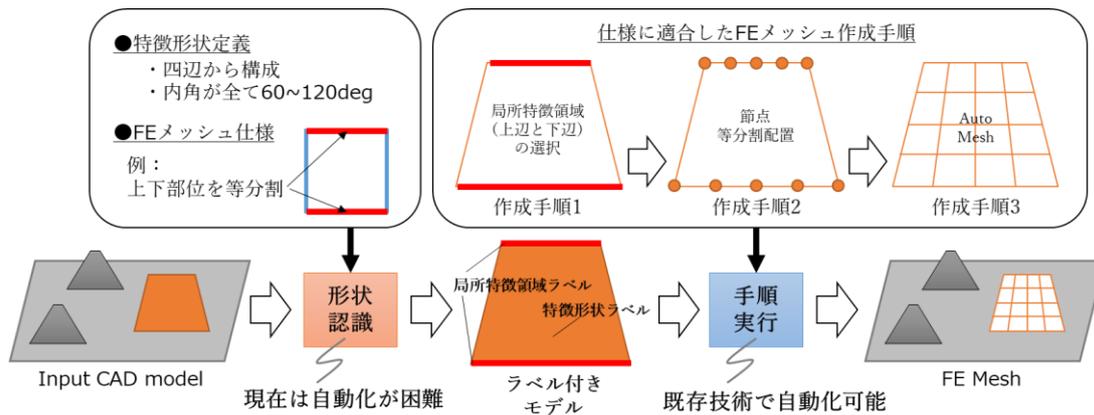


図 1-1-4 作成手順逐次実行方式 FE メッシュ自動生成

このように、既存技術を活かした FE メッシュ自動生成技術を開発することは、CAE モデル自動生成システムの早期実用化のために重要である。そのため、本研究は、提案する 2 つの FE メッシュ自動生成方式それぞれに対応し、以下の要求条件を満たす特徴形状認識技術の開発を目的とする。

●要求条件

- A) 入力 CAD モデルに微小な割れや縮退などの PDQ 劣化部が含まれる場合において、特徴形状認識アルゴリズムが頑健に機能する。
- B) 鋳造部品や樹脂部品に一般的に見られる複雑で滑らかな曲面で構成された特徴形状、及び滑らかに接続された複数の特徴形状において、特徴形状認識アルゴリズムが頑健に機能する。
- C) 異なる特徴形状タイプや、形状や寸法が類似する特徴形状に対し、個別の処理アルゴリズムを設計する必要がなく、統一的で拡張性の高いアルゴリズムで動作する。
- D) 特徴形状認識結果を後工程の FE メッシュ自動生成に利用する手段が議論されている。

1-2 関連研究

本研究は、Computer-Aided Design (CAD) 及び Computer-Aided Manufacturing (CAM) における形状特徴認識、部分形状認識、三次元物体認識の研究分野に関連している。以下、これらの関連研究について述べ、CAE モデル自動生成の側面から課題点を述べる。

1-2-1 CAD/CAM における形状特徴認識

1990 年代以降、製造技術の分野で特徴抽出技術に関する多くの研究活動が行われきた。とりわけ、CAD モデルから加工形状特徴を抽出する技術が盛んに研究されている [Han00] (図 1-2-1)。これらの研究では、鋭角で明確なエッジに囲まれたスロットやポケットなどの加工形状特徴の抽出を対象としており、そのため、鋳造部品や樹脂成型部品に一般的に見られるボスやリブなどのように複雑で滑らかな曲面で構成された特徴形状の抽出を対象としていない。しかし、CAE モデル自動生成においては、ボスやリブなどの滑らかな曲面で構成された特徴形状の抽出もまた重要であり、技術の開発が望まれる [Takaishi20] (図 1-2-2)。

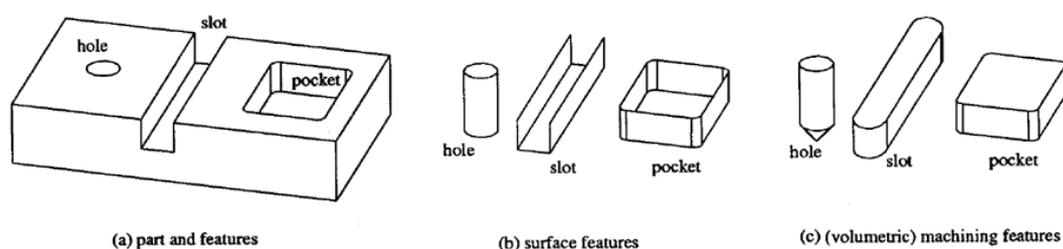


図 1-2-1 加工形状特徴の一例 [Han00]

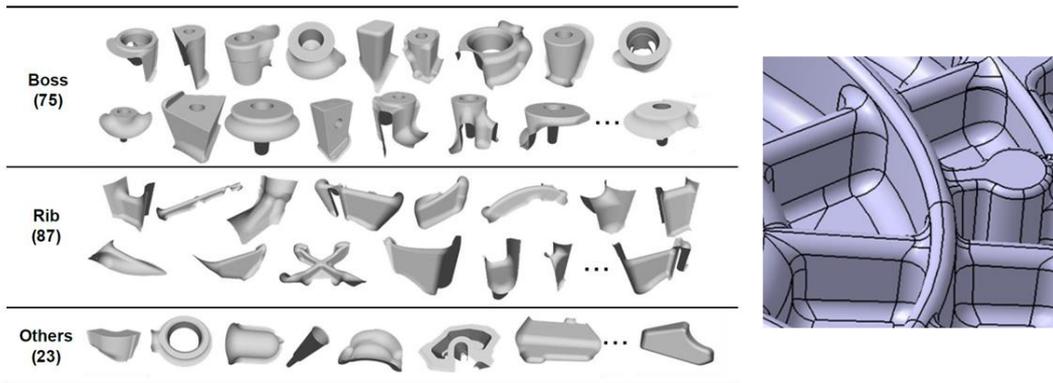


図 1-2-2 滑らかな曲面で構成された特徴形状 (左図[Takaishi20])

一方、滑らかな曲面を含む加工形状を対象とした特徴形状認識技術が研究されている [Sunil08][Cai18][Gupta12]. たとえば、ハイブリッド領域セグメンテーションアルゴリズムを用いたルールベースの特徴形状認識手法が提案されている [Sunil08] (図 1-2-3). この手法では、B-Rep CAD モデルから三角形 STL メッシュモデルを生成し、曲率に基づくルールベースのアルゴリズムにより、板金部品の曲げ部位、ビード部位、ディンプル部位など、様々な凹凸部位の認識を可能にしている. しかし、特徴形状クラスごとに ad hoc なルールが必要となり、多くの特徴形状クラスに対応する場合にはアルゴリズムが非常に複雑になる.

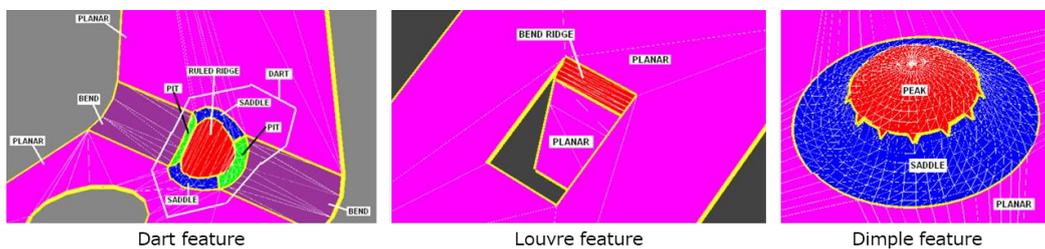


図 1-2-3 三角形メッシュを用いた滑らかな曲面の特徴形状認識手法 [Sunil08]

また、B-Rep CAD モデルの三角形メッシュ分割、及び曲率に基づく領域セグメンテーション手法と接続グラフに基づくクラス分類手法を用いたルールベースの加工形状特徴認識手法が提案されている [Xu15] (図 1-2-4)。この手法では、B-Rep CAD モデルから生成された三角形メッシュを用いて、STEP-NC 加工形状特徴の認識が可能になる。しかし、この論文では、くぼみや突起など、明確なエッジに囲まれた特徴形状の抽出にのみ着目しており、複雑で滑らかな曲面で構成される特徴形状の抽出については検証されていない。また、接続グラフに基づくルールベースのアルゴリズムであるため、特徴形状クラスごとに ad hoc なルールが必要となり、多くの特徴形状クラスに対応する場合にはアルゴリズムが非常に複雑になる。

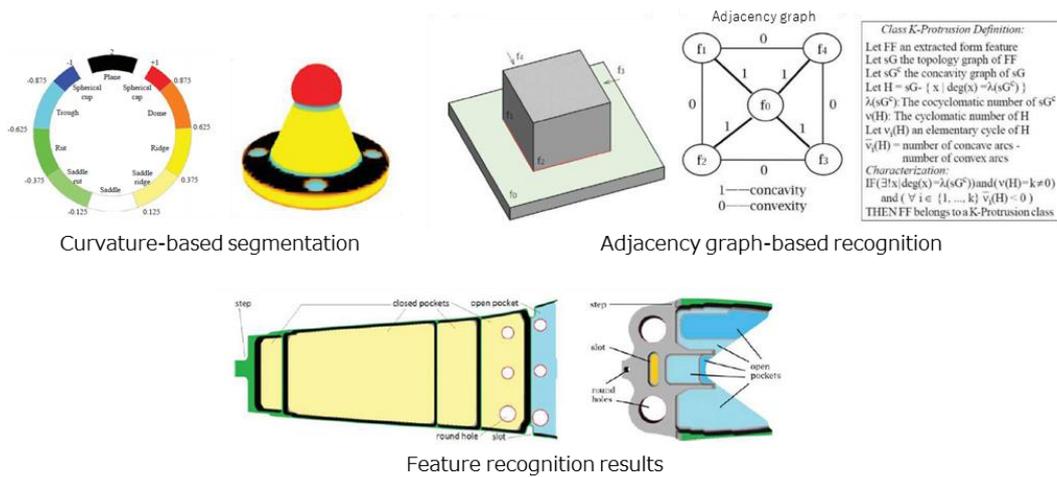


図 1-2-4 三角形メッシュを用いた加工形状特徴認識手法 [Xu15]

近年、B-Rep CAD モデルの三角形メッシュ分割と Heat Kernel Signature (HKS) を用いた加工形状特徴の認識手法が提案されている [Harik17][Shi18] (図 1-2-5)。HKS は、熱拡散方程式の基本解である熱核に基づいた特徴記述子であり、三角形メッシュの各頂点に与えられた単位熱量の拡散における空間的特徴と時間的特徴から形状の類似性を評価する。この手法は、統一的なアルゴリズムを用いて、CAD モデルから加工形状特徴領

域をセグメンテーションできるため、これまでの手法と比較して特徴形状に対して汎用性がある。しかし、これらの論文では、くぼみや突起など、明確なエッジに囲まれた単純な特徴形状の抽出にのみ着目しており、複雑で滑らかな曲面で構成される特徴形状の抽出、又は滑らかに接続される複数の特徴形状の抽出については検証されていない。さらに、この手法の最も大きな問題は、HKSのみを使用して特徴形状クラスを直接的に識別したり分類したりできないことである。そのため、HKSの結果を用いて特徴形状クラスに分類する ad hoc なアルゴリズムを後処理として追加する必要がある。CAEモデル自動生成においては、様々な特徴形状に対して定義されるFEメッシュ仕様に対応する必要がある、特徴形状の分類機能が欠ける HSK ベースのアプローチでは汎用性に欠ける。

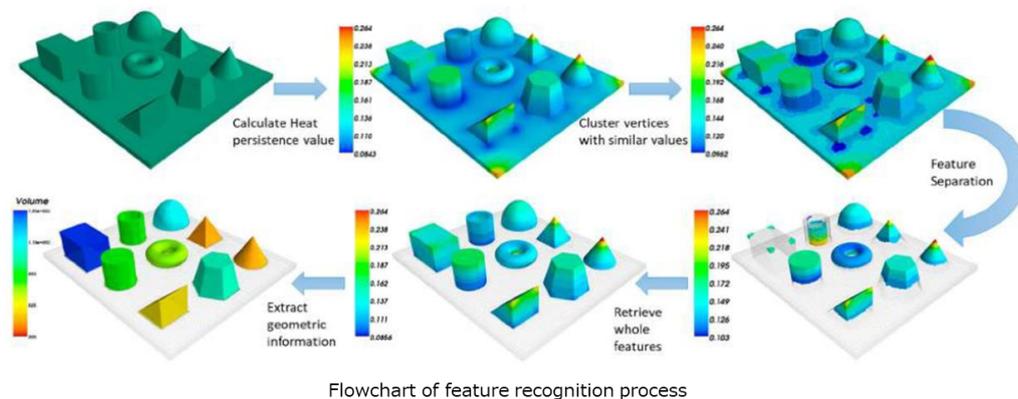


図 1-2-5 Heat Kernel Signature (HKS) による特徴形状抽出手法 [Shi18]

加工形状特徴の抽出手法に関する研究とは異なり、FEメッシュ自動生成を目的とした特徴形状認識に関する研究は、それほど盛んではなかったが、近年になり多く報告されるようになった [Boussuge15][Lai18][Lu01][Onodera19][Wang17][Wu14] (図 1-2-6～図 1-2-9)。それらのほとんどは、グラフベース又はルールベースのアプローチにより CAD モデル上の特

微形状を抽出する手法である。ルールベースアプローチとして、特徴形状抽出及びボリューム分割を用いた手法が提案されている [Boussuge15] [Lu01][Wu14]。これらの手法は、直方体や円筒形状などの基本形状やスイープで生成される形状を対象としており、六面体 FE メッシュの自動生成に適した手法である。しかし、これらの手法は、比較的単純な形状にボリューム分割できる形状を対象としており、鋳造部品や樹脂成型部品に見られる複雑で滑らかな曲面で構成される特徴形状が含まれる場合、ボリューム分割が困難になる。また、CAD モデルに割れなどの PDQ の問題がある場合、抽出アルゴリズムが堅牢に機能しない。さらに、特定の形状特徴タイプに対して専用のアルゴリズムやルールを作り込んでいるため、ある特徴形状クラスの抽出機能を追加するには、専用のアルゴリズムやルールを新たに設計して実装する必要があり、多くの特徴形状クラスに対応する場合にはアルゴリズムやルールが非常に複雑になる。

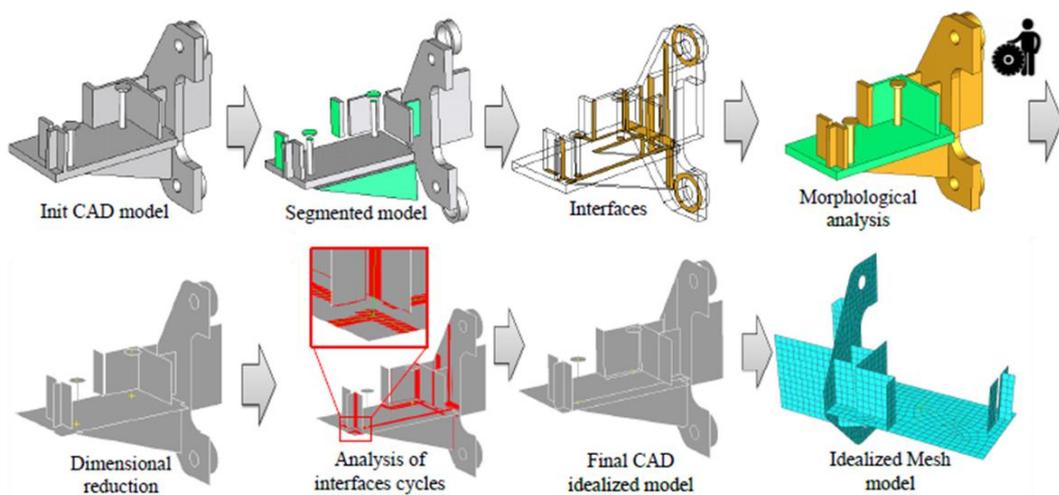
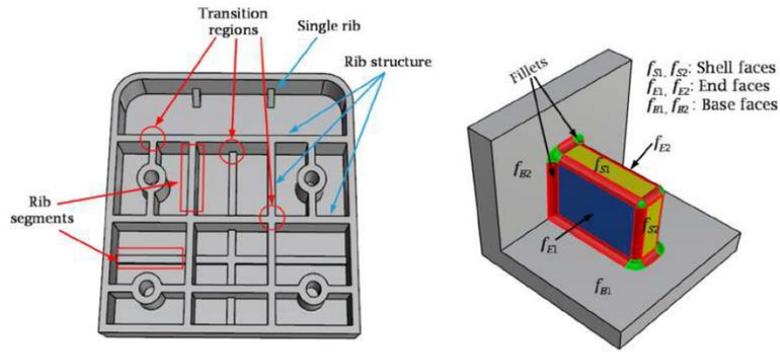
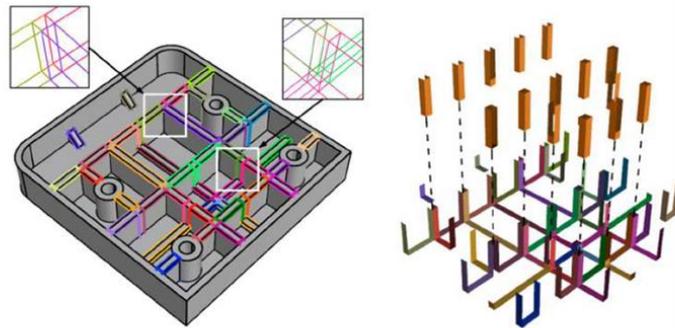


図 1-2-6 FE メッシュ自動生成のためのグラフベースボリューム分割手法 [Boussuge15]



Basic structure of ribs



Results of rib decomposition for the second CAD model

図 1-2-7 FE メッシュ自動生成のためのルールベース特徴形状認識手法 [Lai18]

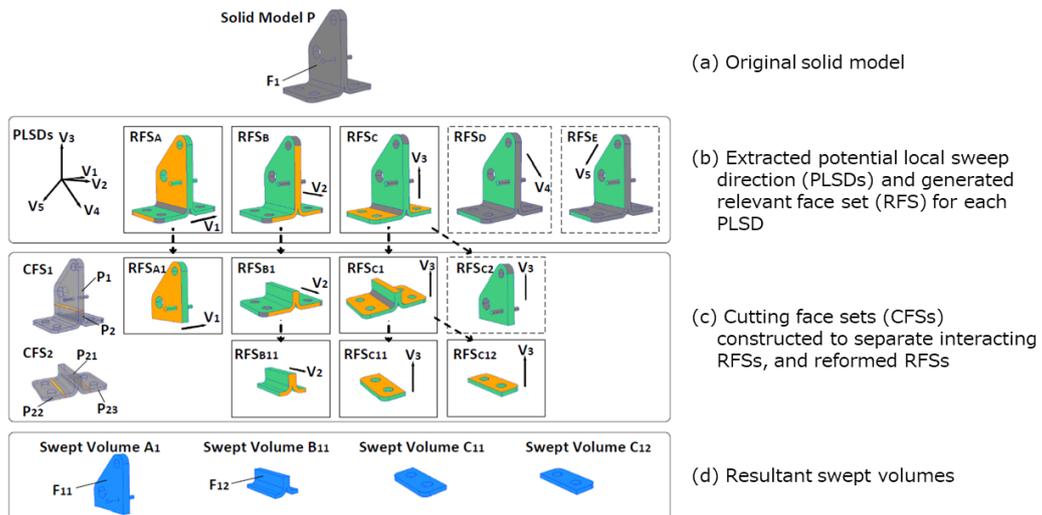


図 1-2-8 六面体 FE メッシュ自動生成のためのスイープ形状ボリューム分割手法 [Wu14]

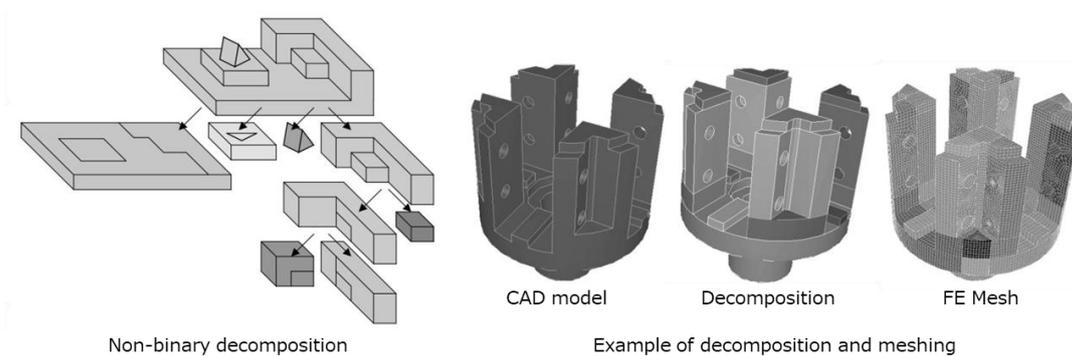


図 1-2-9 六面体 FE メッシュ自動生成のためのポリウム分割手法
[Lu01]

また，滑らかな曲面で構成される形状全体を FE メッシュ分割する手法が提案されている[Yu20][Yu21] (図 1-2-10). この手法は，CAD モデルから生成された表面三角形メッシュに対し，重心ボロノイ分割 (Centroidal Voronoi Tessellation, CVT) を用いて単純形状領域にセグメンテーションし，六面体を主とした FE メッシュを生成する．しかし，CVT による表面領域セグメンテーションに加え，手作業によるセグメンテーションが必要であり課題が残る．また，六面体 FE メッシュで構成された CAE モデルは，計算が安定し比較的高い精度の解が得られるが，形状によってモデル化が困難な場合があることから，実際の CAE 現場での利用範囲は限定されている．そのため，六面体を主とした FE メッシュ自動生成の必要性は必ずしも高くはない．

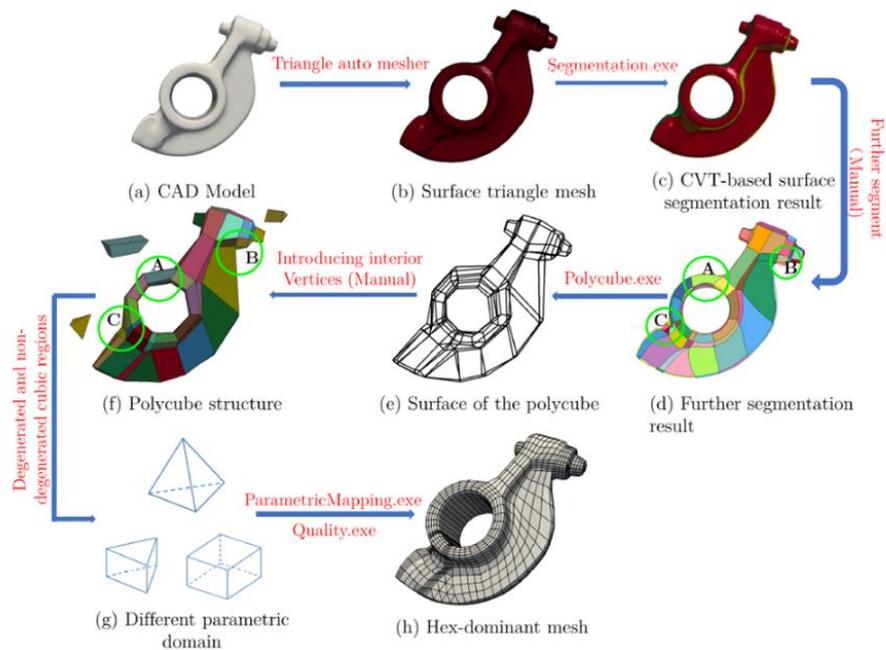


図 1-2-10 滑らかな曲面で構成される特徴形状に対応可能な FE メッシュ生成手法の一例 [Yu21]

さらに、CAD モデルから加工形状特徴を認識する手法の一つとして、従来型ニューラルネットワークに基づく機械学習アプローチが研究されている [Lankalapalli97][Nezis97][Prabhakar92][Sunil09][Peddireddy20]. しかし、2次元画像に奥行き情報を追加した 2.5次元の形状データに基づく手法であり、また、平面と円柱のみで構成された単純形状や、鋭く明確なエッジに囲まれた境界を持つ特徴形状を対象としているため、鋳造部品や樹脂成型部品に一般的に見られる滑らかで複雑な境界に囲まれたリブやボスなどの特徴形状に対して十分に機能しない可能性がある。

近年になり、機械部品 CAD モデルの加工形状特徴を学習する三次元畳み込みニューラルネットワーク (Deep 3D Convolutional Neural Networks, 3D-CNNs) が提案されている [Zhang18] (図 1-2-11). この深層学習ネットワークは、大規模三次元モデルデータセットを通して複雑な加工形状特徴を学習し、特徴形状認識プロセスの自動化を可能にする。この手法は、ボクセ

ルのような低レベルの形状データから特定の加工形状特徴クラスを認識することができる。しかし、先のニューラルネットワークアプローチと同様に、単純な形状や、明確なエッジに囲まれた境界を持つ特徴形状を対象としているため、鋳造部品や樹脂成型部品に一般的に見られる滑らかな曲面で構成されたリブやボスなどの特徴形状に対して十分に機能しない可能性がある。

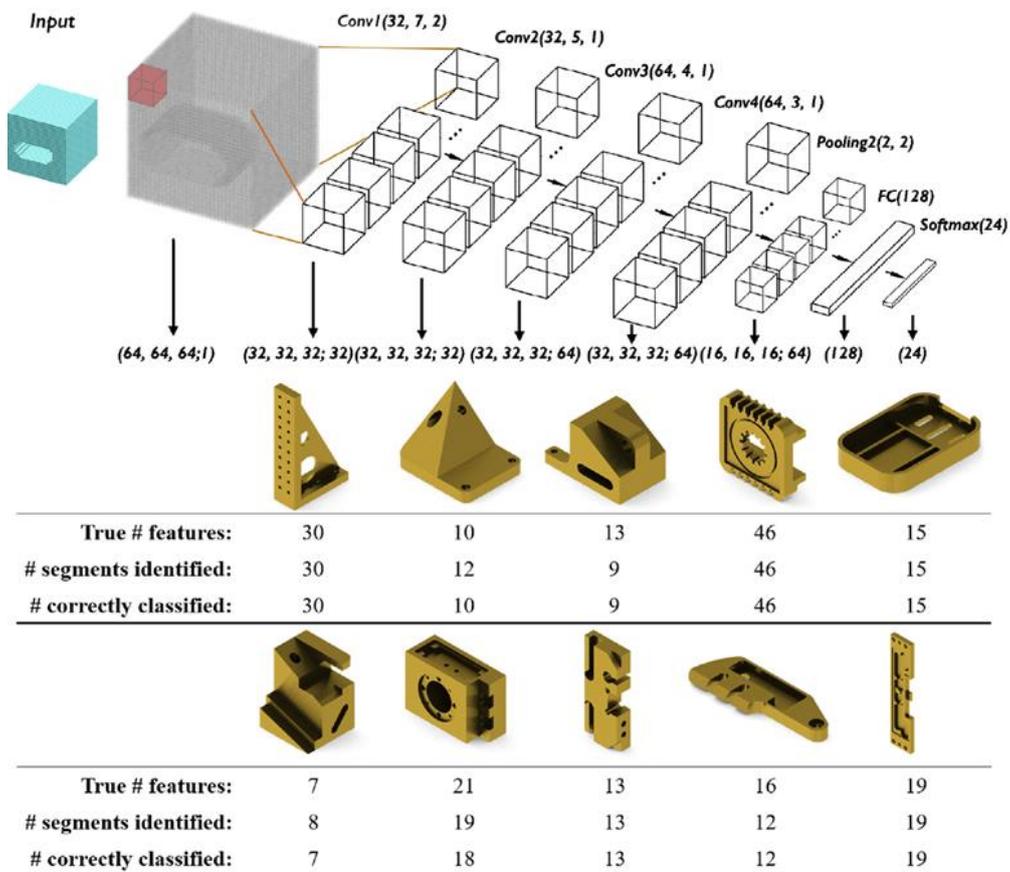


図 1-2-11 三次元畳み込みニューラルネットワークに基づく
加工形状特徴認識手法 [Zhang18]

1-2-2 部分形状認識

主にコンピュータグラフィックス (CG) や 3D メッシュ処理の分野において、三次元形状検索技術が盛んに研究されている [Iyer05][Tangelder08]. 全体形状の中から与えられた部分形状をマッチングにより検索する部分全体形状マッチングは、これらの手法の一つであり、ターゲット形状の中に参照形状と類似する局所領域を見つける特徴形状抽出手法と本質的に同じである. たとえば、ノイズが含まれる三角形メッシュ間の部分全体マッチングにより、参照形状に最もよく一致する形状をターゲット形状の局所領域として発見できる手法が提案されている [Itskovich10] (図 1-2-12). このアプローチでは、特徴点の類似性とセグメントの類似性を統合して評価し、さらに、確率的フレームワークにより特徴点の類似確率を決定する. この手法は、考古学の分野において、建築物に含まれる特定の彫刻模様を発見する場合などに効果的であるが、参照形状と変形関係にある類似形状を発見する場合や、形状の境界が比較的鋭いエッジで構成される工業製品を対象とする場合には、有効に機能しない可能性がある. また、認識結果を FE メッシュ自動生成などの後工程で利用する手段が議論されていない.

他の部分形状認識手法の 1 つとして、参照形状に一致するターゲット形状上の局所領域を効率的に検出する Fast Reject スキーマが提案されている [Attene10] (図 1-2-13). このスキーマは、反復アルゴリズムに基づいており、多数の小さな表面領域をマルチフィールド局所形状記述子で評価し、参照形状に類似していないターゲット形状上の局所領域を破棄していくことで類似領域を特定する. ボクセルベースのラスタ表現オブジェクトに Fast Reject スキーマを適用し、その有効性が示された. しかし、形状記述子間の距離閾値のみによって類似度を制御するため、参照形状と全体的な形状は類似しているが、局所的には大きく異なる部位を含む場合も類似と認識される場合があり、パラメトリックな変形関係にある類似形状のみを抽出することが困難である. また、工業製品を対象とした場合の有効性は十分に検証されていない.

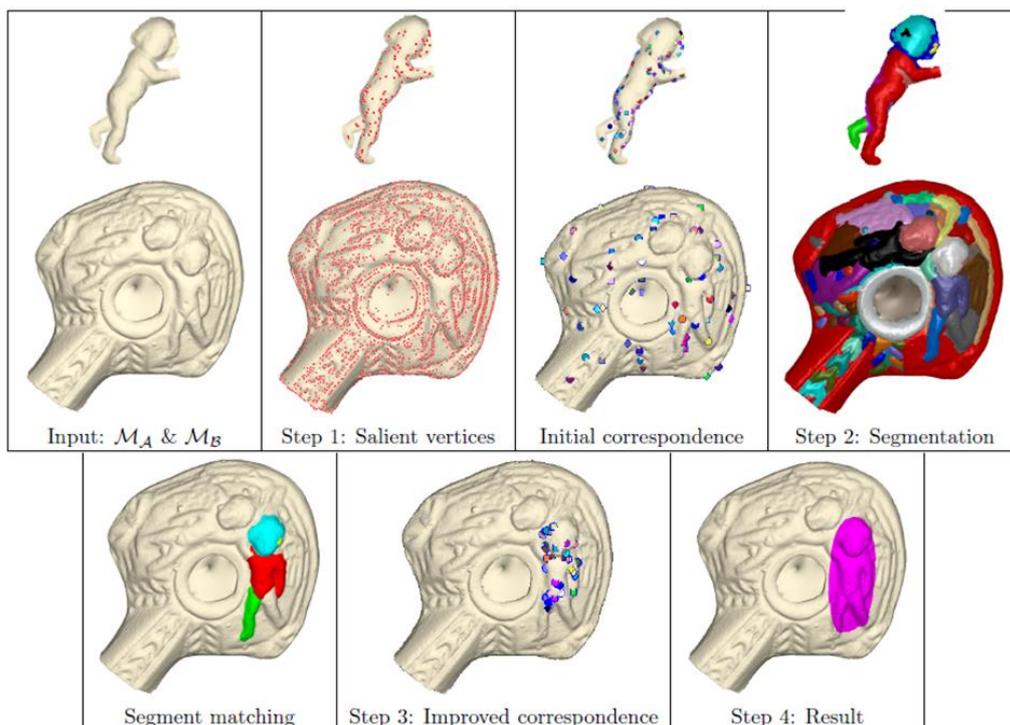


図 1-2-12 3D メッシュによる部分全体形状マッチング手法
[Itskovich10]

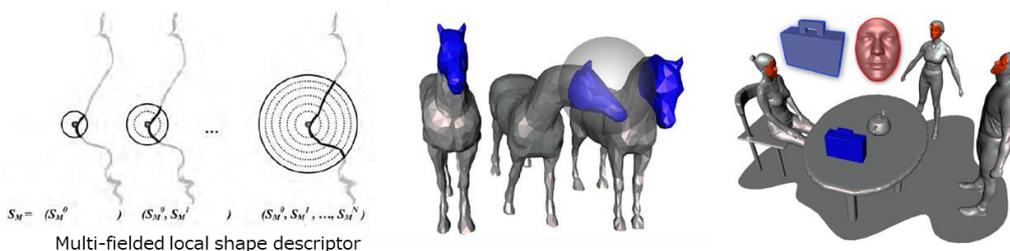


図 1-2-13 Fast Reject スキーマによる部分全体形状マッチング
[Attene10]

さらに、形状コンテキスト記述子を用いた部分全体形状マッチングのアプローチにより、レーザースキャンで取得した点群から土木構造物の 3D モデルを再構成するシステムが提案されている [Hidaka15] (図 1-2-14)。このシステムにより、レーザースキャン点群から橋脚など土木構造物を定義する主

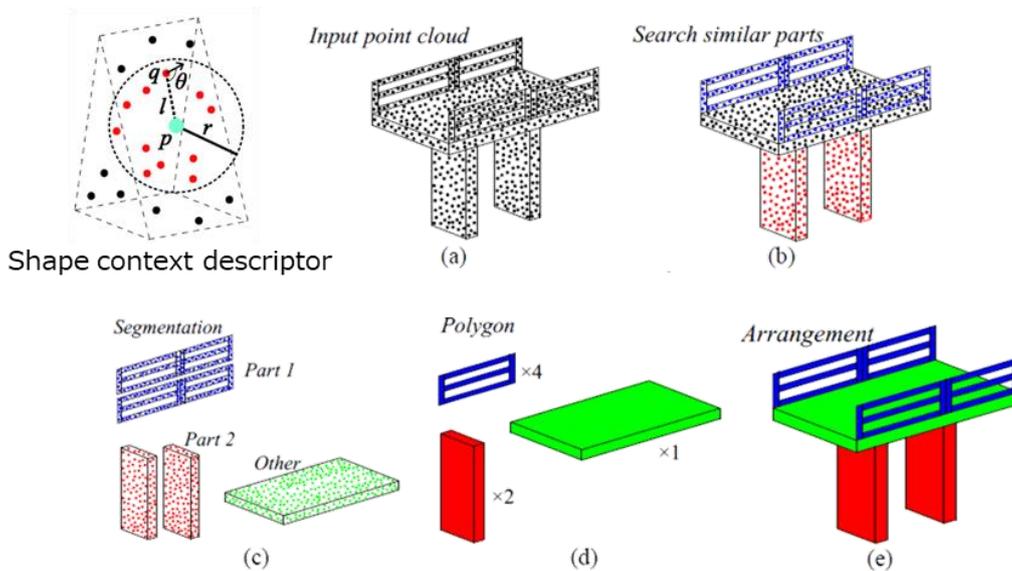
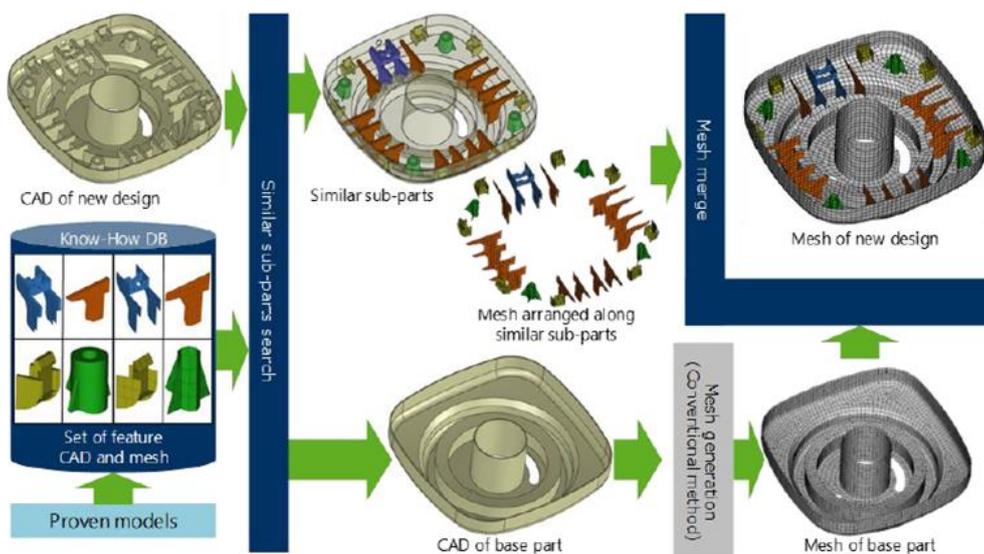


図 1-2-14 部分全体形状マッチングに基づく土木構造物の 3D モデル再構成システム [Hidaka15]

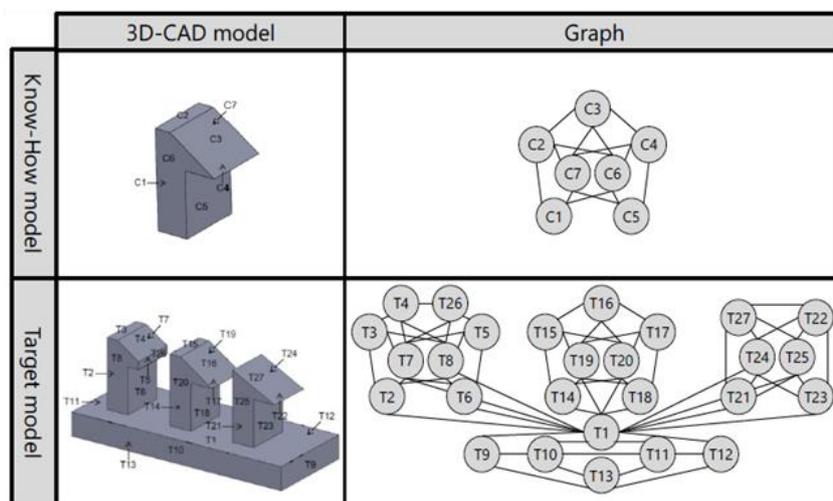
要な部品を抽出することができる。しかし、土木構造物を構成する直方体や円柱といった単純な特徴形状の抽出のみを対象としているため、鋳造部品や樹脂成型部品に一般的に見られる複雑で滑らかな曲面で構成されたリブやボスなどの特徴形状に対して十分に機能しない可能性がある。

一方、予め用意した FE メッシュを割当てする再利用型 FE メッシュ自動生成システムの開発を目的とした部分全体形状マッチングのアプローチが提案されている [Onodera19] (図 1-2-15)。このアプローチは、データベース上に予め用意した参照形状を用いて、CAD モデル上から幾何学的類似性に基づいた類似形状部位を抽出する。データベース上に参照形状 CAD モデルとそれに関連付いた FE メッシュを予め用意するため、類似形状部位の抽出と FE メッシュの割当ての高速実行を可能にする。しかし、この部分特徴形状検索手法では、CAD モデルの面接続関係から得られるグラフの位相構造に強く依存している。そのため、CAD モデルに PDQ の問題がある場合や、幾何学的類似性が高くても位相構造が異なる形状を抽出する場合において正常に機能しない。また、特定の形状特徴タイプに対して専用のアルゴリズムの作り込み

が必要であり，ある特徴形状クラスの抽出機能を追加するには，専用のアルゴリズムを新たに設計して実装する必要がある，多くの特徴形状クラスに対応する場合にはアルゴリズムが非常に複雑になる．



The similar sub-part search technique

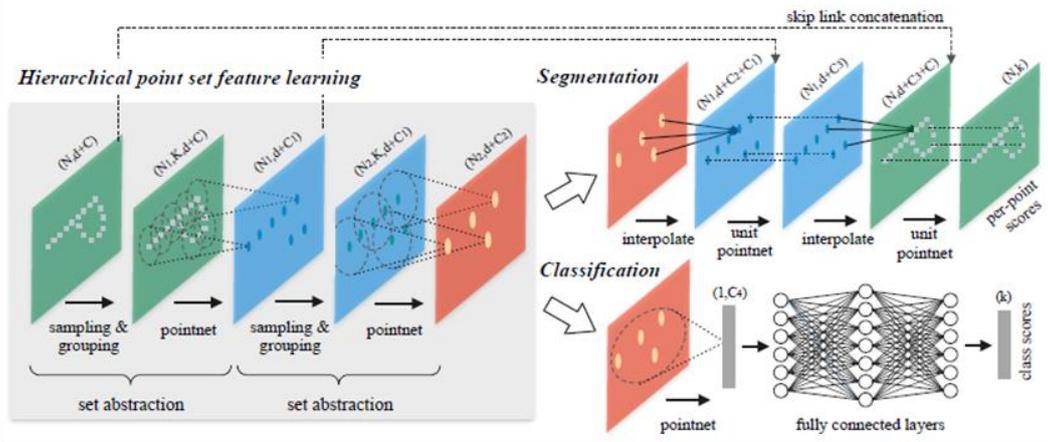


3D-models and graphs

図 1-2-15 FE メッシュ自動生成のためのグラフベース類似部分形状検索手法 [Onodera19]

深層学習は、CAD モデルの特徴形状認識に対する斬新で魅力的なアプローチである。近年、三次元点群を用いた深層学習が盛んに研究されており [Guo20]、三次元点群で表現されたオブジェクトの分類とセグメンテーションに対するいくつかのニューラルネットワークが提案されている [Qi17-1][Qi17-2][Su18][Yuan18]。ただし、多くの深層学習ネットワークの研究では、分類やセグメンテーションが比較的容易なテーブル、椅子、人、動物、飛行機など、構造が明確で単純な形状の組合せから成るオブジェクトを用いて検証されており、複雑で滑らかな曲面で構成されたリブやボスなどの局所的な特徴形状が含まれる鋳造部品や樹脂成型部品などの工業製品を用いた有効性検証は十分に行われていない。特に、工業製品は、人や動物などのように全体と部分の関係性（手、足、頭、胴体など）が明確ではないため、オブジェクト全体を学習させ分類とセグメンテーションを行う一般的な方法では、製品又は部品の全体形状の中から、その部分構造であるリブやボスなどの特徴形状を認識することが困難である。さらに、三次元形状を扱う深層学習では、トレーニングデータセットの準備に多大な労力が必要になることが、以前から問題となっている。滑らかな曲面から構成される三次元形状のトレーニングデータセットを準備する場合には、特に労力がかかることから実用の観点で大きな課題が残る。

PointNet++は、点群深層学習ネットワークの一つであり、分類及びセグメンテーションにおいて高い形状認識性能が示されている [Guo20][Qi17-2] (図 1-2-16)。階層構造型のネットワークを採用することで、PointNet で課題となっていた局所形状の認識精度を向上させている。ただし、他の深層学習ネットワークと同様に、工業製品における有効性検証は十分に行われておらず、また、トレーニングデータセットの準備にかかる労力は依然として課題である。



Neural network structure of PointNet++

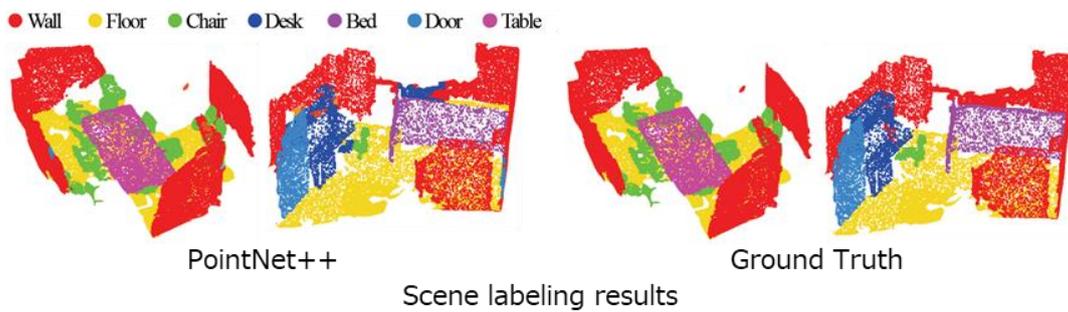


図 1-2-16 三次元点群深層学習ネットワーク PointNet++ [Qi17-2]

1-2-3 三次元物体認識

三次元コンピュータビジョン及びロボット工学の分野では、レーザースキャン等で得られた三次元点群の中から、特定の参照形状と一致する物体を検出する三次元物体認識技術が開発されている。形状記述子を用いたキーポイントマッチングは、物体検出に有効な手段の一つである。形状記述子とは、その形状を代表する特徴を数値に変換し特徴ベクトルとして表す形状記述手法である[Iyer05][Tangelder08].

形状記述子タイプの一つとして、ヒストグラムベースの形状記述子が開発されている[Ankerst99][Ip02][Wohlkinger11][Osada02]. 形状分布記述子は、ヒストグラムベースの形状記述子の一つであり、表面メッシュ上でランダムに選択された2つのポイントの間の距離のヒストグラムによりオブジェクト全体の形状分布を表現する[Osada02] (図 1-2-17). しかし、これらのアプローチは、形状全体の類似性を評価することを目的としており、CAEモデル自動生成を目的とした局所特徴形状認識には適さず、コンテンツベースの三次元形状検索に適している。

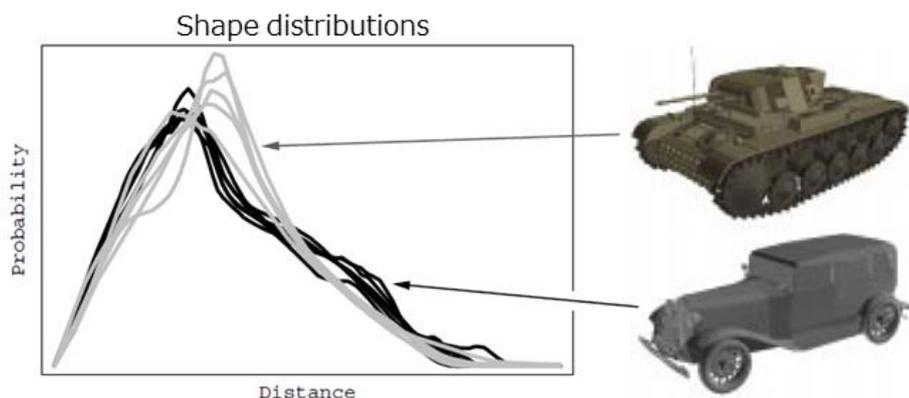


図 1-2-17 形状分布記述子によるオブジェクトの類似性評価 [Osada02]

三次元形状の測定点群上の物体検出を目的とした多くの形状記述子が提案されている [Tombari10][Drost10][Hansch14][Rusu08][Rusu09]. PFH (Point feature histograms) 形状記述子は, 位置と姿勢に対して不変な性質を持ち, キーポイントを中心としたサポート球内のそれぞれの点とキーポイントのペアごとにおける距離や法線角度などをヒストグラム化した局所形状記述子である [Rusu08]. また, FPFH (Fast point feature histograms) は, PFH をベースにキーポイントとその近傍点のみでペアを構成し高速化した局所形状記述子である [Rusu09] (図 1-2-18). PFH と TH (Thickness histogram, [Lui09]) に基づく機械学習アプローチにより滑らかな曲面で構成される特徴形状を分類する手法が提案されている [Takaishi20] (図 1-2-19). しかし, 他の機械学習手法と同様に, トレーニングデータセットの準備にかかる労力は依然として課題である.

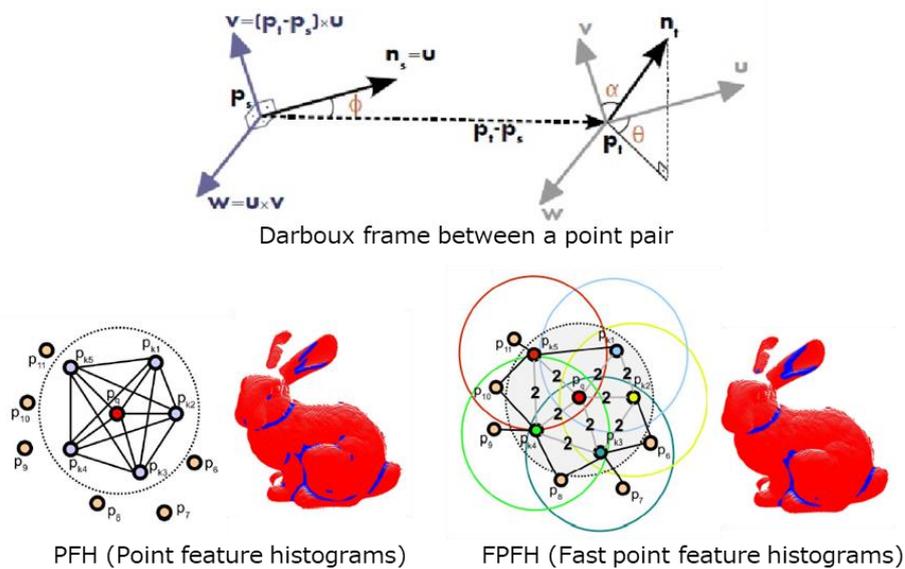


図 1-2-18 PFH 形状記述子及び FPFH 形状記述子 [Rusu09]

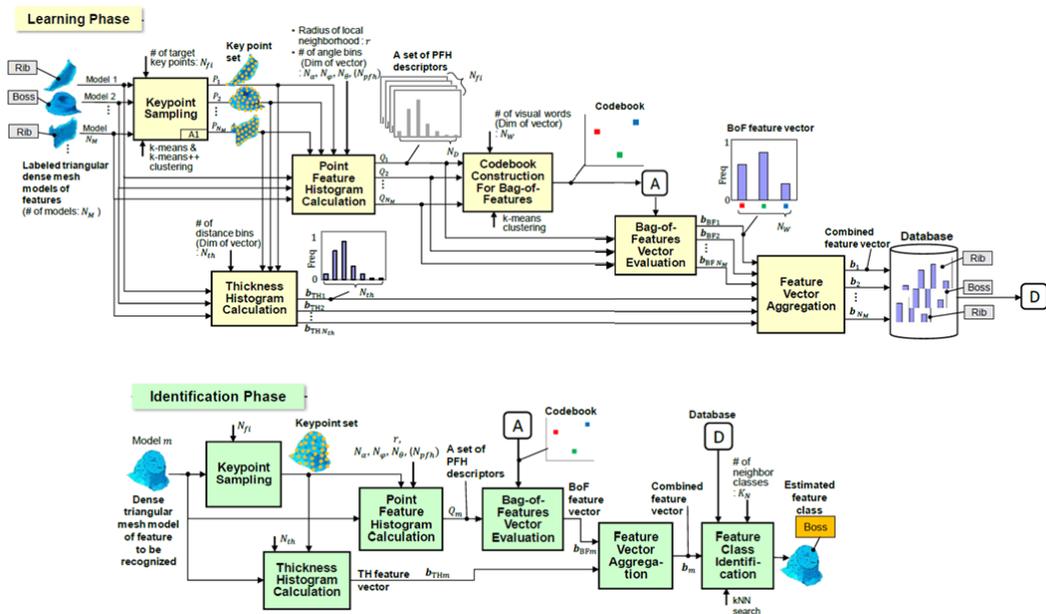


図 1-2-19 PFH 及び TH に基づく機械学習アプローチによる形状分類手法 [Takaishi20]

SHOT (Signature of histograms of orientations) 形状記述子は，位置と姿勢に対して不変な性質を持ち，キーポイントを中心点としたサポート球内の点群で構成される局所形状の曲率分布をヒストグラム化し高次元ベクトルとした局所形状記述子であり，高い形状表現能力を持つ [Hansch14][Tombari10] (図 1-2-20). 具体的には，キーポイント上の法線ベクトルと，サポート球内の点群上の各法線ベクトルとの内積値を計算し，その結果を計算点が位置するサポート球内の分割領域に投票してヒストグラム化する。

PPF (Point pair feature) 形状記述子は，位置と姿勢に対して不変な性質を持ち，三次元形状の測定点群に含まれる全ての2点ペアの点間距離と法線を用いた形状記述子であり，物体検出におけるオクルージョンに強い性質を持つ [Drost10] (図 1-2-21).

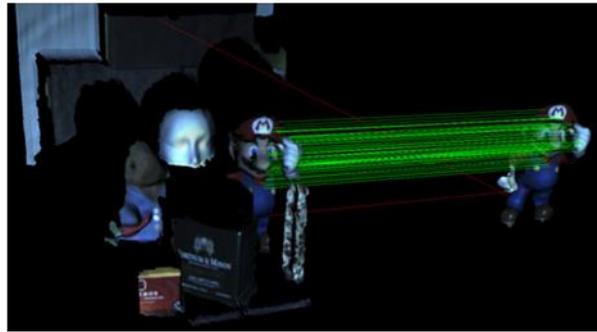
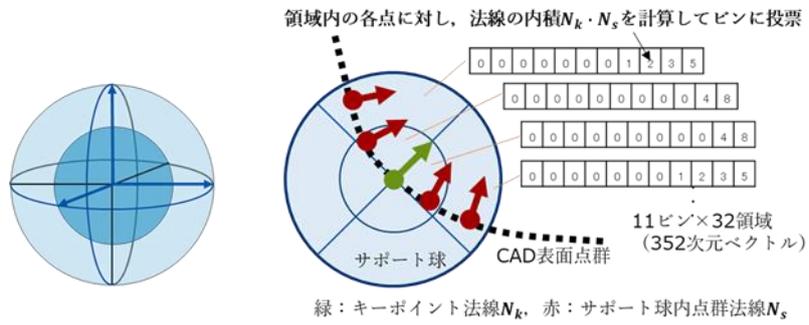


図 1-2-20 SHOT 形状記述子 (下図[Tombari10])

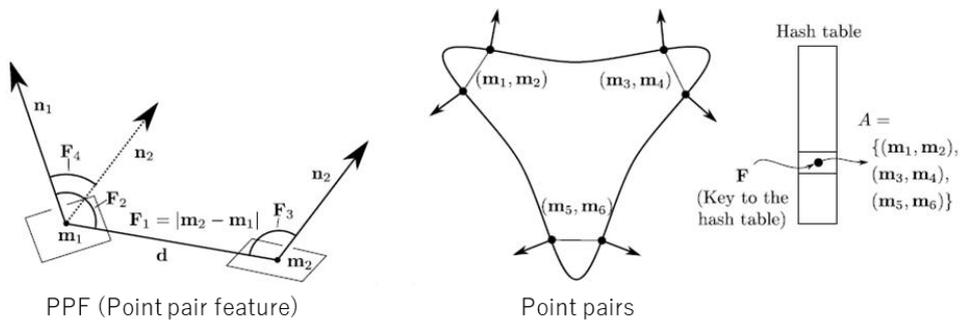


図 1-2-21 PPF 形状記述子 [Drost10]

これらの形状記述子をベースとした物体認識は、測定点群の中に参照形状と正確に一致する領域を発見することを目的としており、FE メッシュ生成のように参照形状と類似する部分形状を検索しなければならない場合は、特殊なアルゴリズムの設計が必要になる。

一方、Shape Index (SI) 形状記述子は、キーポイント上の主曲率を用いて局所的な曲面形状タイプを表現する形状記述子であり、PHF, FPFH, SHOT, PPF と同様に位置と姿勢に対して不変な性質を持ち、さらに、スケール不変の性質を持つため、参照形状に対して大きさの異なる類似形状の抽出を可能にする [Koenderink92]。SI は、建築物に含まれる特定の彫刻模様を発見するための考古学分野の手法 [Itskovich10] や、コンピュータ断層撮影 (CT) ボリュームデータからポリープを見つけるため医療科学分野の手法にも用いられている [Poo13][Yoshida01] (図 1-2-22)。しかし、これらの手法では、参照形状とターゲット形状内の特徴形状が等方スケーリングの関係であることを前提としているため、異方スケーリングの関係にある特徴形状を発見する場合は、特殊なアルゴリズムの設計が必要になる。

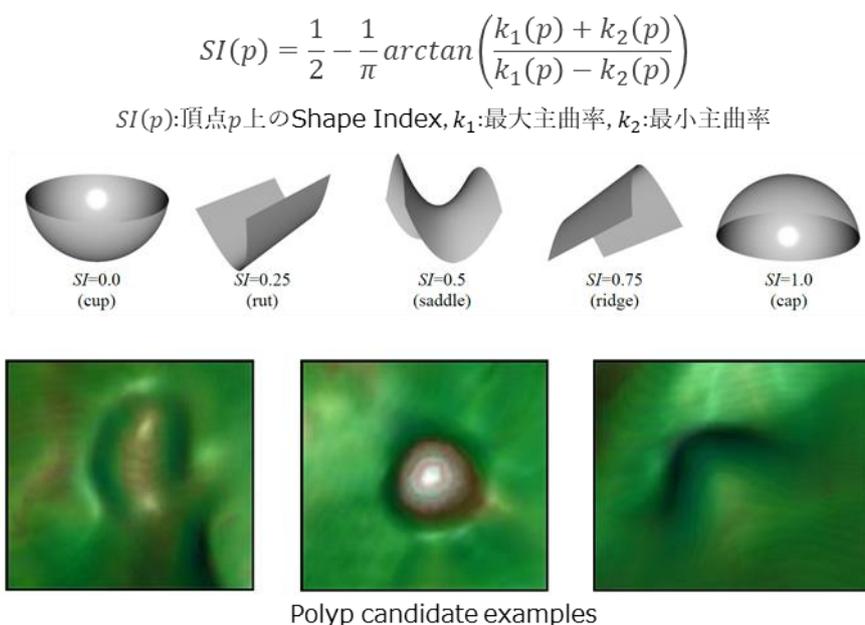


図 1-2-22 SI 形状記述子によるポリープ検出の一例 (下図 [Poo13])

1-3 本研究の目的と特徴

1-3-1 従来手法の問題点

前述したように、CAE モデル自動生成を目的とし、CAD モデル上から特徴形状を自動認識する様々な手法が提案されており、特定条件下において有用性を示している。しかし、これらの従来手法には、仕様適合 FE メッシュ生成を想定した CAD モデル上からの特徴形状抽出における、1-1 節で述べた要求条件 ABCD の観点から、以下の問題がある。

従来手法の問題点（図 1-3-1）

- A) CAD モデルに微小な割れや縮退などのモデルデータ品質 (Product Data Quality, PDQ) の問題が含まれている場合、特徴形状認識アルゴリズムが頑健に機能しない。
- B) 鋳造部品や樹脂部品に一般的に見られる複雑で滑らかな曲面で構成された特徴形状、及び滑らかに接続された複数の特徴形状において、特徴形状認識アルゴリズムが頑健に機能しない。
- C) 異なる特徴形状タイプや、形状や寸法が類似する特徴形状に対し、特徴形状タイプ毎に ad hoc な処理アルゴリズムの実装が必要であり、統一性と拡張性に欠ける。
- D) 特徴形状認識結果を後工程の FE メッシュ自動生成に利用する手段が議論されていない。もしくは FE メッシュ生成自体を研究のスコープとしていない。

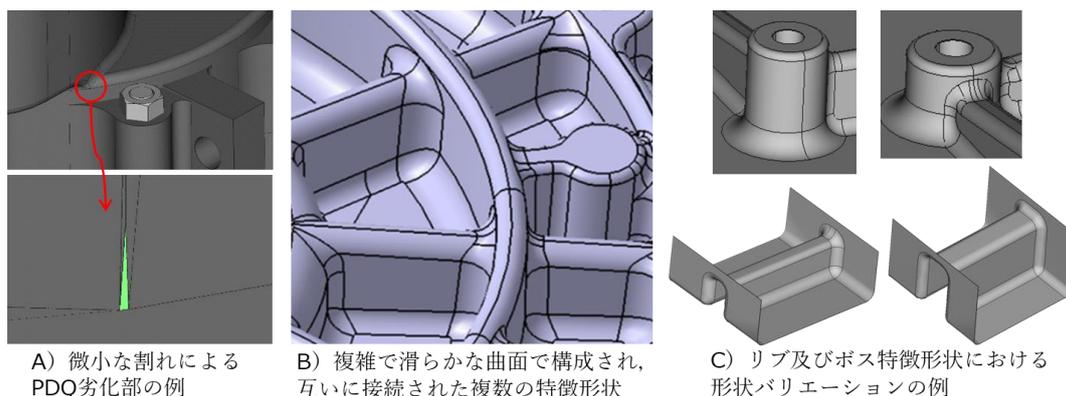


図 1-3-1 従来手法の問題点

1-3-2 本研究の目的

前節の問題点を考慮し、本研究では、製品又は部品形状 CAD モデルを入力とし、特徴形状毎に規定された仕様に適合した FE メッシュを自動生成するため、PDQ 劣化部を含む入力 CAD モデルや、複雑で滑らかな曲面で構成された特徴形状が含まれる入力 CAD モデルに対する認識が頑健に動作し、さらに、特徴形状タイプの違いに依存せず統一的で拡張性の高いアルゴリズムで動作する三次元特徴形状認識技術の開発を目的とする。

1-3-3 手法及びその特徴

上記の研究目的を達成するため、本研究では、図 1-3-2 にあるように、CAD モデル表面を高密度の三次元点群に変換し、その離散的形状表現を活用した独自の特徴形状認識手法を開発したことに大きな特徴をもつ。この離散的形状表現を導入することで、これまでコンピュータビジョンやロボティクス分野で利用されてきた局所形状記述子を用いた類似形状認識技術、並びに三次元点群深層学習を用いた分類及びセグメンテーション技術を応用した特徴形状認識手法の 2 つの特徴形状認識手法を実現し、1-3-1 節で述べた従来の特

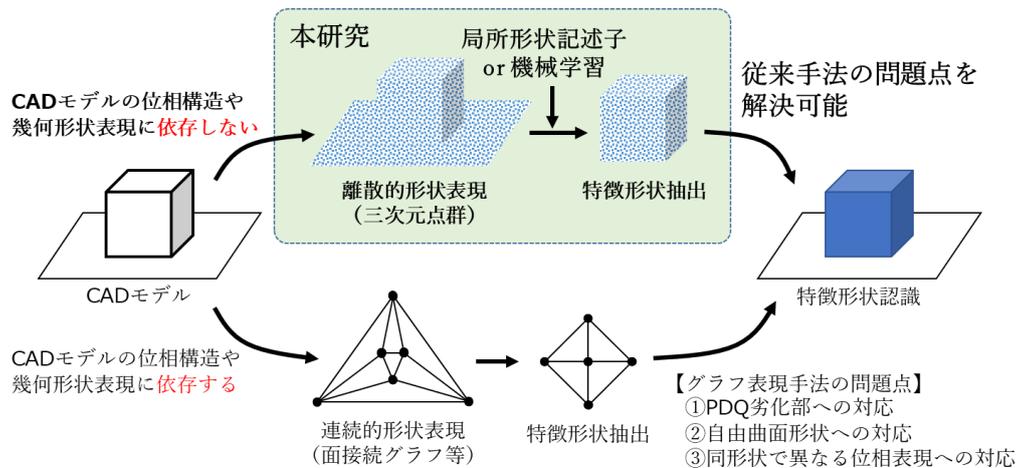


図 1-3-2 離散的形状表現を活用した特徴形状認識手法

微形状認識手法の問題点の解決を図った。その解決方法を以下に整理する。

従来手法の問題点に対する解決方法

A) PDQ劣化部が含まれる入力 CAD モデルを用いた認識への対応

入力 CAD モデルを離散的形状表現である三次元点群に変換することで、CAD モデルの位相構造に依存せず、点の空間分布にのみ依存する特徴形状認識を可能にし、入力 CAD モデル上に微小な割れや縮退などの PDQ 劣化部があり、不連続な面分が存在していても、頑健に機能する特徴形状認識アルゴリズムを実現した。

B) 複雑で滑らかな曲面で構成された特徴形状の認識への対応

入力 CAD モデルを離散的形状表現である三次元点群に変換することで、CAD モデルの幾何表現形式や面分境界形状に依存せず、ポイントの空間分布にのみ依存する特徴形状認識を可能にし、特徴形状が複雑で滑らかな曲面で構成されているか、又は複数の特徴形状が互いに複雑で滑らかに接続されているかに関係なく、頑健に機能する特徴形状認識アルゴリズムを実現した。

C) 統一的で拡張性の高い認識アルゴリズムへの対応

離散的形状表現である三次元点群を活用することで、ポイントの空間分布にのみ依存した形状特徴量を、形状記述子又は深層学習により抽出し、その類似性に基づく特徴形状認識を可能にした。これにより、新たな特徴形状タイプや、形状や寸法が類似する特徴形状の認識に対し、個別にアルゴリズムを設計することなく、参照データ又はトレーニングデータを追加することのみで対応できる統一的で拡張性の高い特徴形状認識アルゴリズムを実現した。

D) 認識結果を FE メッシュ自動生成に利用する手段への対応

マッピング方式及び作成手順逐次実行方式それぞれの FE メッシュ自動生成に必要な特徴形状認識結果の出力を、提案する特徴形状認識手法において実装した。

実現した 2 つの特徴形状認識技術の概要を以下に述べる。

(1) 手法 1：三次元点群と形状記述子を用いた類似特徴形状認識技術

図 1-3-3 に示すように、予め用意した FE メッシュを変形してマッピングする FE メッシュ自動生成方式を前提とした形状認識手法である。製品形状 CAD モデル表面の高密度三角形メッシュ分割により得られる三次元点群を用いたキーポイントと形状記述子により、製品形状 CAD モデル上から、予め用意した参照特徴形状とパラメトリックな形状変換関係にある局所類似特徴形状を抽出する。抽出時に得られる射影変換行列を用いることで、データベース上の参照特徴形状 CAD モデルに関連付いた FE メッシュ等を、発見形状にマッピングして CAE モデルを生成することが可能になる。

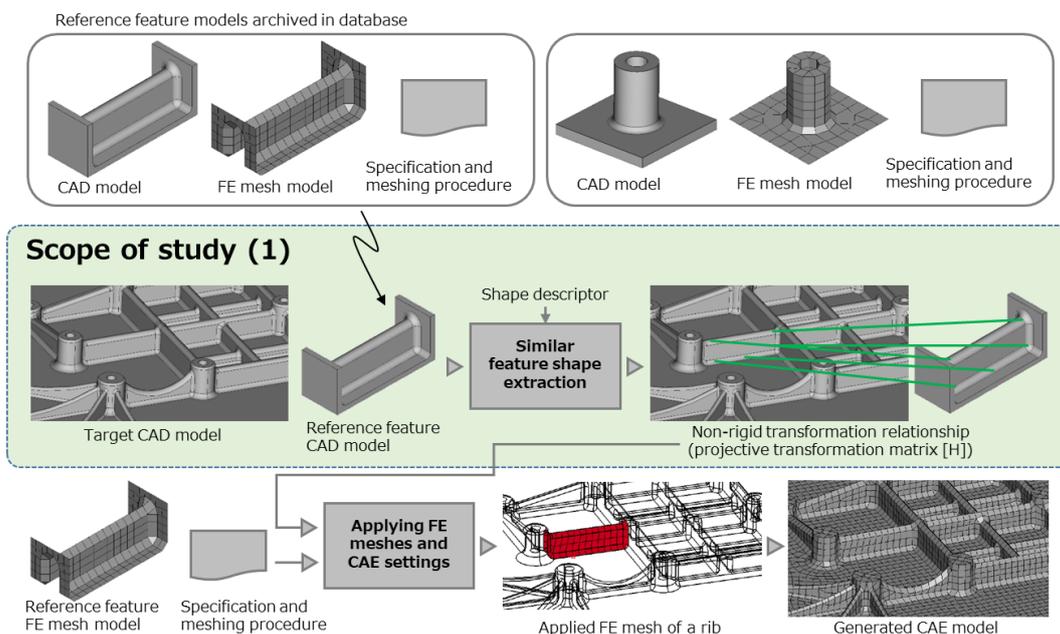


図 1-3-3 手法 1：三次元点群と形状記述子を用いた類似特徴形状認識技術の研究スコープ

手法 1 では、射影変換行列で表現可能な変換関係までを抽出対象の形状としているため、1つの参照特徴形状から抽出できる形状の範囲は狭く、また、データベース上の参照特徴形状バリエーションにより抽出可能な形状範囲が決まる。しかし、データベースに参照特徴形状を追加することは容易であり、そのため、データベースを拡充することで、抽出できる特徴形状範囲を容易に拡大できるという特徴を持つ。また、入力 CAD モデル上の一部の特徴形状を切り出して参照特徴形状とすることで、同一 CAD モデル上の類似特徴形状を検索する利用法も想定している。さらに、データベースに登録する参照特徴形状の情報に特徴形状クラスや局所特徴領域の情報を持たせることで、抽出された特徴形状に対し、作成手順逐次実行方式 FE メッシュ自動生成を適用することも可能になる。

この手法 1 の詳細については、第 2 章で論じる。

(2) 手法 2 : 三次元点群と深層学習を用いた自由曲面特徴形状認識技術

手法 2 は、図 1-3-4 に示すとおり、識別された特徴形状及び局所特徴領域に適用すべき FE メッシュ仕様を、その作成手順に基づき、商用 CAE プリソフトウェアのマクロ機能を用いてコマンドを逐次自動実行することで FE メッシュを生成する作成手順逐次実行方式を前提とした特徴形状認識技術である。製品形状 CAD モデル表面の高密度三角形メッシュ分割により得られる三次元点群を用いた深層学習アプローチにより、特徴形状を検出し、その特徴形状を構成する局所特徴領域を識別する。識別された局所特徴領域にラベル付けし、そのラベル情報を用いたルールベースの逐次処理を CAE プリソフトウェアのマクロ機能で実行することにより CAE モデルの自動生成が可能になる。

手法 2 では、特徴形状及び局所特徴領域を定義でき、さらに、機械学習アプローチで認識可能である形状クラスを認識対象としている。また、複雑で滑らかな曲面で構成される特徴形状の発見を可能にする機械学習手法とするため、高さや幅など特定の形状パラメータを駆動させてパラメトリックな関係を持つ形状群を生成できる特徴形状クラスを対象としている。

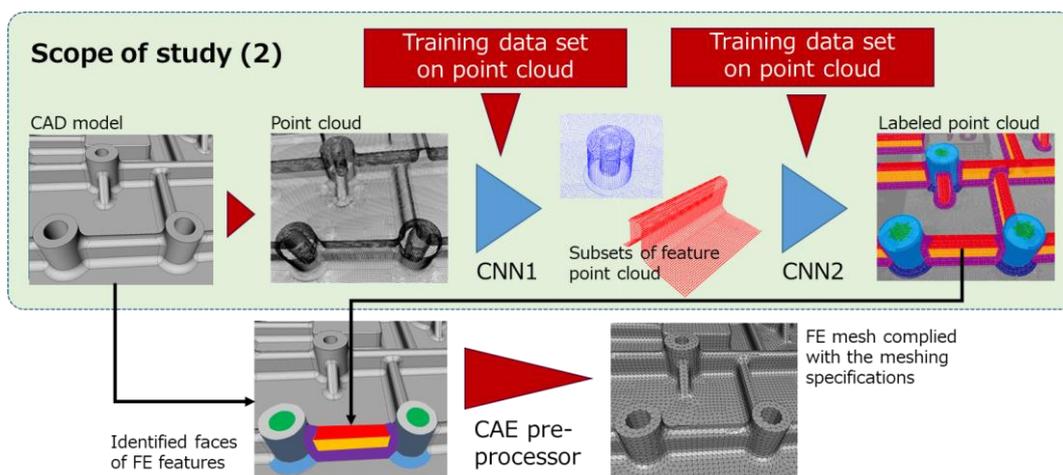


図 1-3-4 手法 2 : 三次元点群と深層学習を用いた自由曲面特徴形状認識技術の研究スコープ

機械学習アプローチにより、トレーニングデータを拡充することで、広範囲の特徴形状の抽出が可能になるという特徴を持つ。さらに、単体の特徴形状及び局所特徴領域を認識するネットワークとしたことで、トレーニングデータ生成において、パラメトリック CAD により多くのバリエーションを自動生成でき、機械学習で一般的に問題となるトレーニングデータの量に関する問題を解決している。一方で、学習ネットワークのトレーニングには多大な計算コストが必要である。そのため、新しい特徴形状クラスを追加する場合、新規トレーニングが必要となり容易ではない。また、本手法は、抽出した特徴形状及び局所特徴領域に対し、基準となる形状は存在せず、また、それらとの相対的な関係式（射影変換行列など）も計算が困難であるため、マッピング方式 FE モデル自動生成には適さない。

この手法 2 の詳細については、第 3 章で論じる。

表 1-3-1 に手法 1 と手法 2 の概要を整理して示す。形状記述子を活用する手法 1 の特徴は、手法 2 に対して、新しい特徴形状タイプに迅速且つ柔軟に対応可能である点であり、また、機械学習アプローチである手法 2 の特徴は、手法 1 に対して、幅広い特徴形状バリエーションを持つトレーニングデータセットでトレーニングした深層学習ネットワークにより、幅広い特徴形状タイプの認識が実行可能になる点である。

このように、手法 1 と手法 2 により、PDQ 劣化部を含む入力 CAD モデルや、複雑で滑らかな曲面で構成された特徴形状が含まれる入力 CAD モデルに対する認識が頑健に動作し、さらに、特徴形状タイプの違いに依存せず統一的で拡張性の高いアルゴリズムによる三次元特徴形状認識を可能にした。

表 1-3-1 手法 1 と手法 2 の概要

	手法 1	手法 2
対応する FE メッシュ自動 生成方式	マッピング方式	作成手順逐次実行方式
入力データ	製品 CAD モデル, 参照特徴 形状 CAD モデル	製品 CAD モデル
出力データ	射影変換行列	ラベル付き三次元点群
形状表現形式	三次元点群	三次元点群
形状特徴量	局所形状記述子	深層学習ネットワーク
形状認識手法	キーポイントマッチング, RANSAC	点群深層学習, パラメトリッ ク CAD によるデータ増幅
認識可能な形 状範囲	参照特徴形状に対して射影 変換行列で表現可能なパラ メトリック変形関係の範囲	深層学習に使用するトレ ーニングデータセットの形状 バリエーションの範囲
認識可能な形 状範囲の拡張 方法	新しい参照特徴形状 CAD モ デルをデータベースに追加 登録	トレーニングデータセット の拡充と再学習
利用場面	①特徴形状バリエーション が頻繁に変化する場合, ②同 一形状内に類似形状が複数 存在する場合, ③パラメトリ ックに変形できる形状の場 合, ④マッピングで FE メッ シュを生成できる場合	①特徴形状バリエーション がある程度固定されている 場合, ②特徴形状クラスを定 義できる場合, ③学習時間が 確保できる場合, ④ CAE S/W でラベル情報から FE メ ッシュ生成できる場合

1-4 本論文の構成

本論文は 5 章で構成される。第 2 章以降の概要を以下に示す。

第 2 章 三次元点群と形状記述子を用いた類似特徴形状認識技術の開発

提案手法のコンセプトについて述べ、その後、三次元点群表現と形状記述子を用いた類似特徴形状認識処理の全体像及び各処理の詳細を説明する。またその中で、形状記述子、キーポイントマッチング、RANSAC、並びにそれらを組み合わせた参照特徴形状と検索特徴形状間の射影変換関係導出などの特徴形状認識処理に必要な要素技術についての説明を加える。最後に、実験結果を示し有効性を考察する。

第 3 章 三次元点群と深層学習を用いた自由曲面特徴形状認識技術の開発

提案手法のコンセプトについて述べ、その後、三次元点群の深層学習による分類及びセグメンテーション技術を応用した自由曲面特徴形状認識処理の全体像及び各工程の詳細を説明する。またその中で、PointNet++, Multi-Scale Bounding Box (MSBB), Non-Maximum Suppression (NMS) などの要素技術について説明を加える。また、深層学習で必要となる大量の学習データセットを、基準 CAD モデルのパラメトリック変形 (パラメトリック CAD) を用いて、形状パラメータ値の組合せから効率的に大量生成する手法を説明する。最後に、有効性検証実験の結果を示し考察する。

第 4 章 認識特徴形状に基づく FE メッシュ自動生成と提案手法の有効性

検証

提案する手法 1 及び手法 2 で出力される形状認識結果の情報を、その後工程である FE メッシュ自動生成に連携させる具体的な実装方法を述べるとと

もに，部品形状を用いた検証実験とその結果から，本手法の有効性について考察する．

第 5 章 結論と今後の課題

研究内容に関してまとめ，提案手法の今後の展望について述べる．

第 2 章

三次元点群と形状記述子を用いた 類似特徴形状認識技術の開発

2-1 特徴とアルゴリズムの概要

本手法は，製品形状 CAD モデルを入力とし，特徴形状毎に規定された仕様に適合した FE メッシュをマッピング方式により自動生成することを前提とした類似特徴形状認識技術である．また，従来手法での問題点を改善し，PDQ 劣化部を含む CAD モデルや，複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状 CAD モデルに対して頑健に動作し，さらに，特徴形状バリエーションの違いに依存せず統一的で拡張性の高いアルゴリズムで動作する三次元特徴形状認識技術である．

これらを実現するため，入力 CAD モデルの位相構造や幾何表現形式などに依存しない離散的形状表現を採用し，入力される製品形状 CAD モデルを高密度点群に変換して参照形状と類似する特徴形状を発見する．また，コンピュータビジョンやロボティクス分野で提案されてきた局所形状記述子を採用し，形状を数値的に扱うことで類似形状評価を可能にしている．ここで，高密度点群は，CAE プリソフトウェアの FE メッシュ自動生成機能により，入力 CAD モデル表面に生成された三角形メッシュを介して生成される．また，局所形状記述子には，曲率ベースの形状記述子である SHOT と Shape Index を採用しており，高密度点群から計算される．形状の類似性評価は，参照特徴形状と一定の範囲内でパラメトリックな変形関係にある形状を対象としており，RANSAC，局所形状記述子，射影変換行列を用いた独自のアルゴリズムにより行われる．そして，本特徴形状認識手法で最終的に得られる

射影変換行列を用いることで、参照特徴形状と関連付いた FE メッシュを変形して入力 CAD モデル上にコピーする、マッピング方式 FE メッシュ自動生成を実現可能にする。

本手法で採用した局所形状記述子の SHOT と Shape Index は、曲率をベースとしており、曲率以外の形状因子の影響を受け辛く、様々な形状バリエーションに対して頑健に動作する。また、SHOT 形状記述子は、本来、完全一致形状の検出を目的に設計された局所形状記述子であるが、特徴空間上の距離による一致閾値の幅を広くすることで類似性の評価が可能になるよう独自に拡張し、RANSAC 及び射影変換行列と組み合わせることで、複雑で滑らかな曲面で構成される特徴形状に対しても、射影変換で表されるパラメトリックな変形関係の範囲において、類似特徴形状の抽出を可能にしている。さらに、これらのアルゴリズムは、入力 CAD モデルの様々なバリエーションに対して統一的に適用できるため、特徴形状をデータベースに追加登録するだけで、抽出したい形状バリエーションを拡充することが可能になる。

本手法のアルゴリズムは、図 2-1-1 に示すとおり、6 つの STEP から構成されており、前半の STEP 1~3 は、参照特徴形状と入力 CAD モデルを局所形状記述子に変換する処理フェーズであり、後半の STEP 4~6 は、入力 CAD モデル上の類似特徴形状を抽出する処理フェーズである。

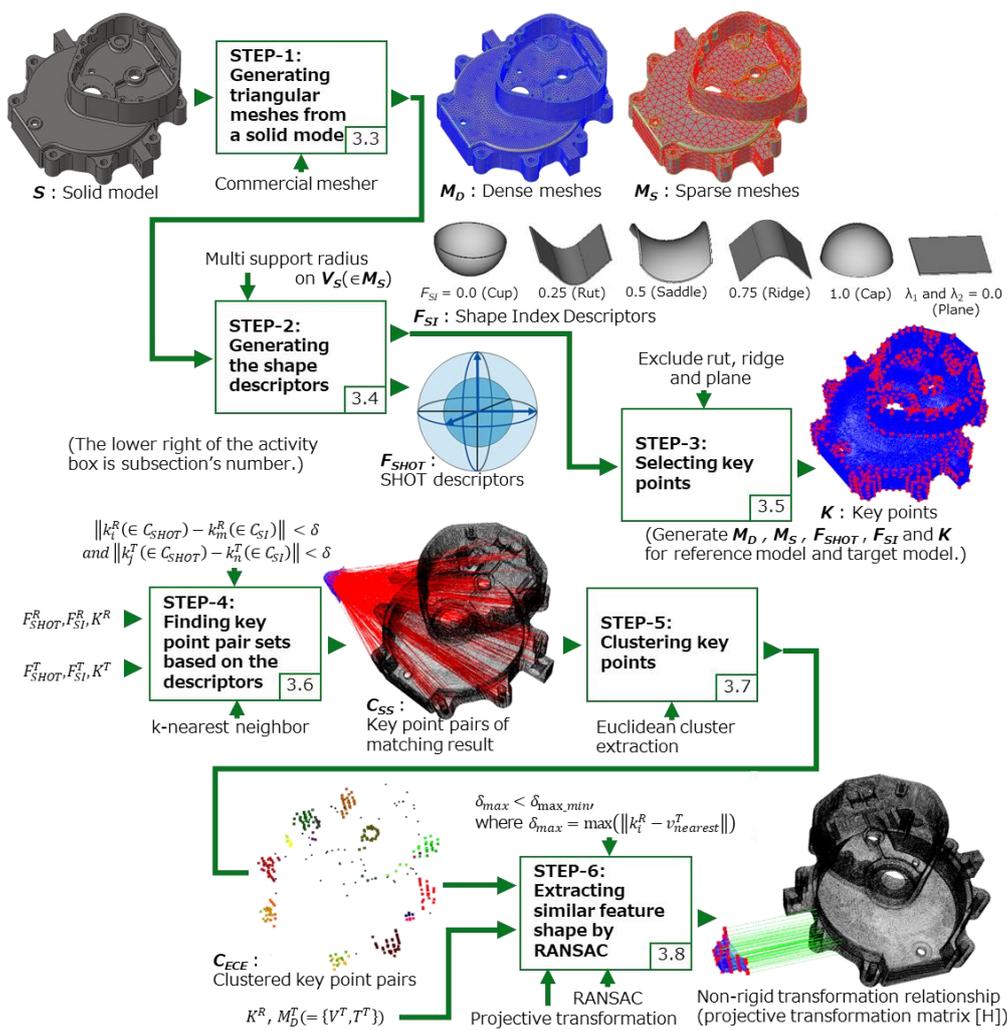


図 2-1-1 三次元点群と形状記述子を用いた類似特徴形状認識技術のアルゴリズムの概要

2-2 アルゴリズムの詳細

本節では、図 2-1-1 の各 STEP における処理の詳細について述べる。

2-2-1 STEP1 : CAD モデル表面上の三次元点群生成

1つの入力 CAD モデル S^T の表面上に高密度三角形メッシュ $M_D^T = \langle V_D^T, T_D^T \rangle$ と低密度三角形メッシュ $M_S^T = \langle V_S^T, T_S^T \rangle$ を CAE プリソフトウェアの自動メッシュ生成機能を用いて生成する。ここで、 V_D^T と T_D^T は、それぞれ高密度三角形メッシュ M_D^T の頂点と三角形要素の集合を表し、 V_S^T と T_S^T は、それぞれ低密度三角形メッシュ M_S^T の頂点と三角形要素の集合を表す。また、上付き文字の T は、入力 CAD モデルから生成されていることを表し、下付き文字の D と S は、それぞれ、高密度と低密度を表す。

次に、図 2-2-1 のように、高密度三角形メッシュ M_D^T の頂点集合 V_D^T の各要素 $v_{D,i}^T (\in V_D^T)$ 上の法線ベクトル $\mathbf{n}_{D,i}^T (\in N_D^T)$ を算出し、法線ベクトル集合 N_D^T を生成する。ここで、 i は、 V_D^T 内の頂点番号及びそれに対応する法線ベクトル番号を示す。同

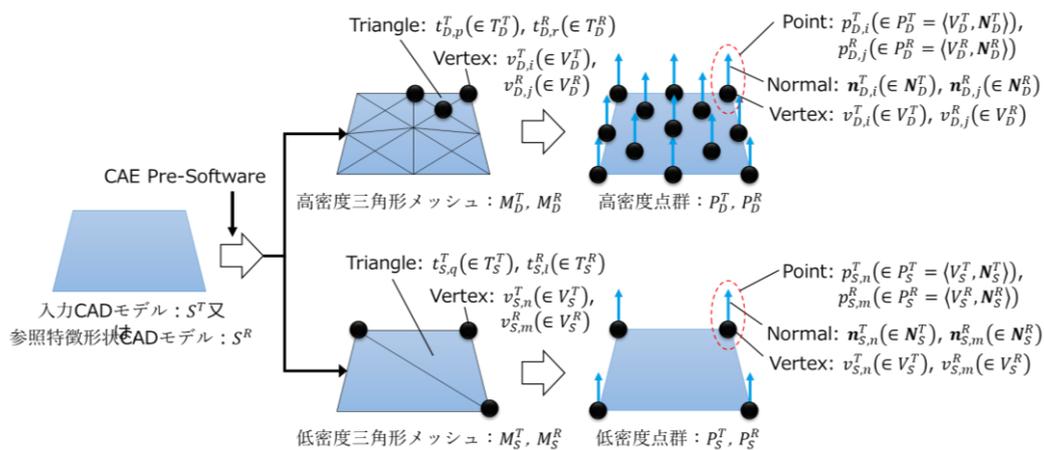


図 2-2-1 三次元点群の生成

様に，低密度三角形メッシュ M_S^T の頂点集合 V_S^T の各要素 $v_{S,j}^T (\in V_S^T)$ 上の法線ベクトル $\mathbf{n}_{S,j}^T (\in N_S^T)$ を算出し，法線ベクトル集合 N_S^T を生成する．ここで， j は， V_S^T 内の頂点番号及びそれに対応する法線ベクトル番号を示す．

これらの頂点集合及びそれに対応した法線ベクトル集合により，入力 CAD モデル S^T の離散的形状表現である法線付き高密度三次元点群 $P_D^T = \langle V_D^T, N_D^T \rangle$ ，及び法線付き低密度三次元点群 $P_S^T = \langle V_S^T, N_S^T \rangle$ を生成する．

同様にして，データベース上に存在する参照特徴形状 CAD モデル S^R の表面に，高密度三角形メッシュ $M_D^R = \langle V_D^R, T_D^R \rangle$ と低密度三角形メッシュ $M_S^R = \langle V_S^R, T_S^R \rangle$ を生成する．ここで， V_D^R と T_D^R は，それぞれ高密度三角形メッシュの頂点と三角形要素の集合を表し， V_S^R と T_S^R は，それぞれ低密度三角形メッシュの頂点と三角形要素の集合を表す．また，上付き文字の R は，参照特徴形状 CAD モデルから生成されていることを表し，先ほどと同様に，下付き文字の D と S は，それぞれ高密度と低密度を表す．

入力 CAD モデル S^T の場合と同様に，高密度三角形メッシュ M_D^R の頂点集合 V_D^R の各要素 $v_{D,n}^R (\in V_D^R)$ 上の法線ベクトル $\mathbf{n}_{D,n}^R (\in N_D^R)$ を算出し，法線ベクトル集合 N_D^R を生成する．ここで， n は， V_D^R 内の頂点番号及びそれに対応する法線ベクトル番号を示す．同様に，低密度三角形メッシュ M_S^R の頂点集合 V_S^R の各要素 $v_{S,m}^R (\in V_S^R)$ 上の法線ベクトル $\mathbf{n}_{S,m}^R (\in N_S^R)$ を算出し，法線ベクトル集合 N_S^R を生成する．ここで， m は， V_S^R 内の頂点番号及びそれに対応する法線ベクトル番号を示す．

先ほどと同様に，これらの頂点集合及びそれに対応した法線ベクトル集合により，参照特徴形状 CAD モデル S^R の離散的形状表現である法線付き高密度三次元点群 $P_D^R = \langle V_D^R, N_D^R \rangle$ ，及び法線付き低密度三次元点群 $P_S^R = \langle V_S^R, N_S^R \rangle$ を生成する．

ここで生成された三次元点群 P_D^T ， P_S^T ， P_D^R ， P_S^R は，局所形状記述子の特徴量計算に用いられる．そのため，低密度三次元点群 P_S^T ， P_S^R の各頂点 $v_{S,j}^T (\in V_S^T)$ ， $v_{D,n}^R (\in V_D^R)$ を，特徴量計算の評価ポイント $p_{eval,j}^T (\in P_{eval}^T \subset P_S^T)$ ， $p_{eval,m}^R (\in P_{eval}^R \subset P_S^R)$ として再定義して利用する．ここで， $P_{eval}^T (\subset P_S^T)$ と $P_{eval}^R (\subset P_S^R)$ は，それぞれ，入力 CAD モデル上及び参照特徴形状上の評価ポイント集合を表す．また，局

所形状記述子の特徴量計算では，評価ポイントを中心とし，その周辺に分布するポイントを計算ポイントとして用いる．ここでは，高密度三次元点群 P_D^T と P_D^R の各頂点 $v_{D,i}^T(\in V_D^T)$ ， $v_{D,n}^R(\in V_D^R)$ を，計算ポイント $p_{calc,i}^T(\in P_{calc}^T \subset P_D^T)$ 及び $p_{calc,n}^R(\in P_{calc}^R \subset P_D^R)$ として再定義して利用する．ここで， $P_{calc}^T(\subset P_D^T)$ 及び $P_{calc}^R(\subset P_D^R)$ は，それぞれ，入力 CAD モデル上及び参照特徴形状上の計算ポイント集合を表す．

さらに，これらの三次元点群は，特徴量マッチングの代表点であるキーポイント点群 $K^T(\subset P_S^T)$ 及び $K^R(\subset P_S^R)$ の選定にも使用される．各キーポイント $k_j^T(\in K^T)$ 及び $k_m^R(\in K^R)$ には，特徴形状を代表する独自性の高いポイントを選択する必要がある．本手法では，一様に分布した初期点群の局所形状特徴量を評価し選択する．その際の初期点群に低密度三次元点群 P_S^T と P_S^R を使用し，最小限の評価ポイント数にすることで，計算コストを抑えている．一方，計算コストを考慮しなくてよい場合は，キーポイントの選択と局所形状特徴量の計算において，同一の三次元点群を使用することができる．

2-2-2 STEP2：局所形状記述子の生成

次に，図 2-2-2 のように，入力 CAD モデル及び参照特徴形状 CAD モデル上に STEP1 で生成した高密度三次元点群 P_D^T と P_D^R ，及び低密度三次元点群 P_S^T と P_S^R を用いて， P_S^T と P_S^R の各ポイント上の局所形状記述子 Shape Index (SI) $f_{SI,j}^T(\in F_{SI}^T)$ と $f_{SI,m}^R(\in F_{SI}^R)$ [Koenderink92]，及び SHOT $f_{SHOT,j}^T(\in F_{SHOT}^T)$ と $f_{SHOT,m}^R(\in F_{SHOT}^R)$ [Hansch14][Tombari10]を計算する．これらの局所形状記述子の特徴量（局所形状特徴量）は，評価ポイント集合 $P_{eval}^T(\subset P_S^T)$ 及び $P_{eval}^R(\subset P_S^R)$ 内の j 番目及び m 番目の評価ポイント $p_{eval,j}^T(\in P_{eval}^T)$ 及び $p_{eval,m}^R(\in P_{eval}^R)$ を中心とした半径 R のサポート球内にある計算ポイント集合 $P_{calc}^T(\subset P_D^T)$ 及び $P_{calc}^R(\subset P_D^R)$ 内の点群によって計算される．

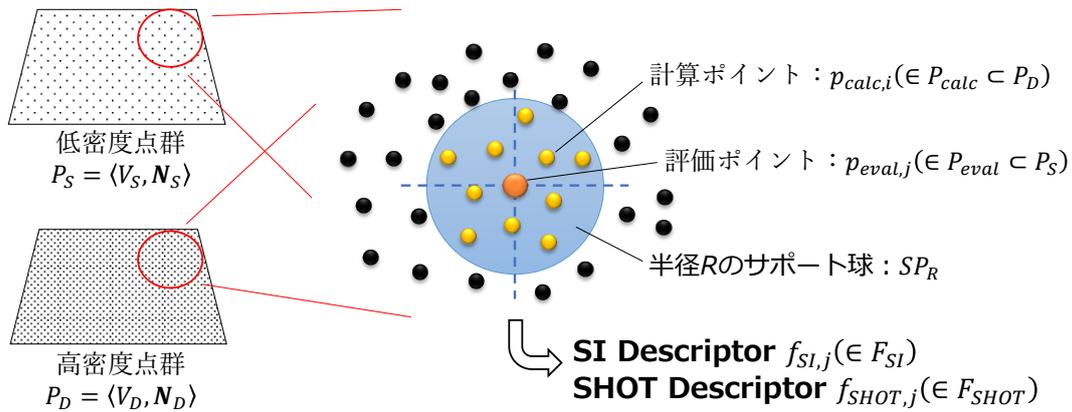


図 2-2-2 局所形状特徴量の計算

SI は、評価ポイント近傍の点群から計算される近似主曲率を用いて局所的な曲面形状タイプを表現する形状記述子であり、汎用性が高く多くの分野で実績がある。位置と姿勢に対して不変な性質を持ち、さらに、スケール不変の性質を持つ。そのため、入力 CAD 形状と参照特徴形状の点群の各ポイントにおける SI を比較することにより、参照特徴形状とスケールの異なる類似特徴形状を入力 CAD 形状から抽出可能であるが、異方スケーリングの関係にある特徴形状を発見する場合は、特殊なアルゴリズムの設計が必要になる。本手法では、後述する RANSAC と射影変換を用いた独自のアルゴリズムにより、異方スケーリングの関係にある類似特徴形状の発見を可能にしている。

ポイント k における SI の計算式[Poo13]を以下に示す。

$$f_{SI,k} = \frac{1}{2} - \frac{1}{\pi} \tan^{-1} \left(\frac{\lambda_1 + \lambda_2}{\lambda_1 - \lambda_2} \right), \quad \text{if } \lambda_1 \text{ and } \lambda_2 \approx 0 \text{ then } f_{SI,k} = -1.0 \quad (2.1)$$

ここで、 λ_1 と λ_2 は、ポイント k 周辺の点群が表す表面の最大主曲率と最小主曲率である。ただし、 λ_1 と λ_2 の値がゼロに近い場合（形状タイプが平面に近い場合）は、 $f_{SI,k}$ を計算できないため、 $f_{SI,k}$ の値を便宜的に負の値に設定する。式 2.1 に従って計算された $f_{SI,k}$ の値によって、図 2-2-3 に示すような局所形状タイプを識別することができる。

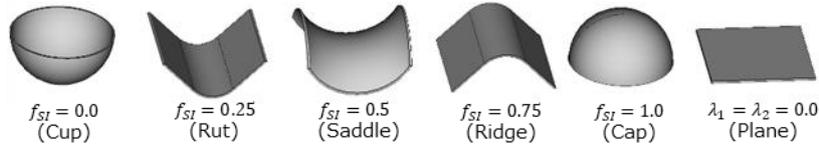


図 2-2-3 Shape Index の値と形状タイプ

一方，SHOT は，剛体変換関係の検出を目的に設計された形状記述子であり，位置と姿勢に対して不変な性質を持つ．評価ポイントを中心点としたサポート球内の点群の近似曲率分布をヒストグラム化した固定長多次元ベクトルにより局所形状を表現するため，形状表現能力が高く，物体検出の分野で多くの実績がある．具体的には，図 2-2-4 にあるように， j 番目の評価ポイント $p_{eval,j} (\in P_{eval})$ を中心としたサポート球を方位角方向に 8 分割，仰俯角方向に 2 分割，半径方向に 2 分割の計 32 領域に分割し，その分割領域のうち， i 番目の計算ポイント $p_{calc,i} (\in P_{calc})$ が存在する領域において， $p_{calc,i}$ 上の法線ベク

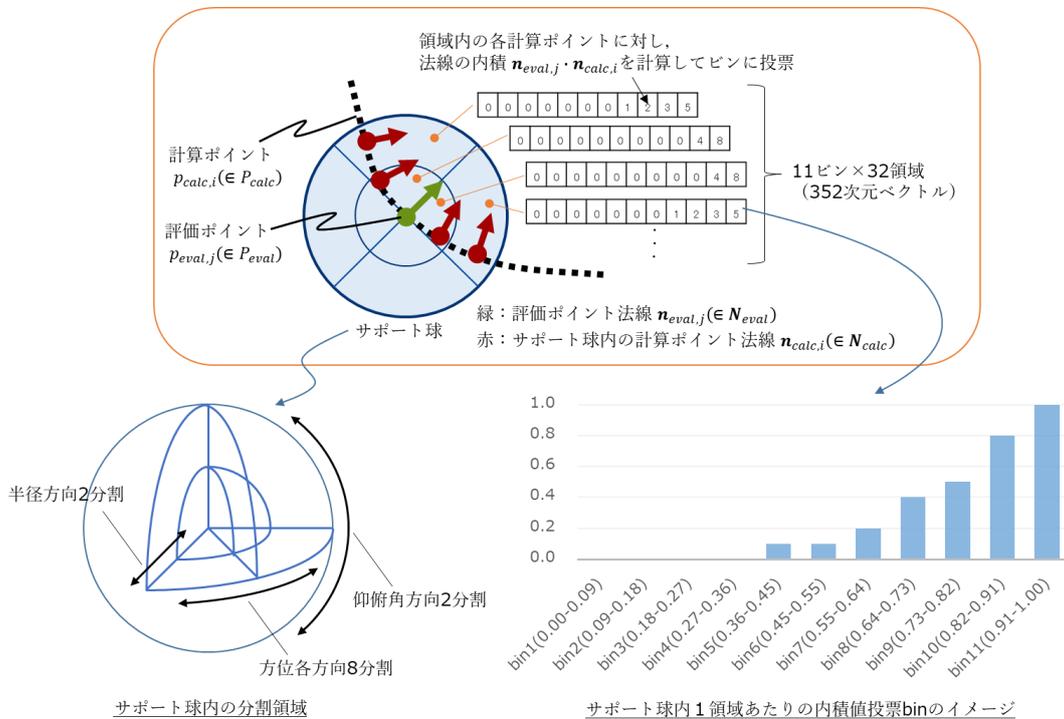


図 2-2-4 SHOT におけるサポート球の分割領域と内積値投票ビン

トルと，サポート球中心点である $p_{eval,j}$ 上の法線ベクトルの内積を計算し，さらに， $0.0 \sim 1.0$ の範囲を等 11 分割した各ビンのうち，計算した内積値が当てはまるビンに投票する．したがって，SHOT 特徴量は， 32 領域 $\times 11$ ビン $= 352$ 次元ベクトルで局所特徴形状を表現する．サポート球内の全ての計算ポイントで内積値を投票し，最後に正規化することで 1 つの評価ポイント $p_{eval,j}$ に対する SHOT 特徴量 $f_{SHOT,j}$ を計算することができる．

本手法では，剛体変換関係にある完全一致形状の検出を目的に設計された SHOT を用いて，パラメトリックな変形関係にある類似形状の認識を行うため，特徴空間上の距離による一致評価の閾値範囲を広くすることで，類似性の評価を可能にした．また，図 2-2-5 のように，サポート球の大きさを変化させたマルチスケール・サポート球を用いて，1 つの評価ポイントに対してスケール違いの複数の SHOT 特徴量を存在させ，後述する特徴量評価のアルゴリズムにより，スケール依存性を軽減している．

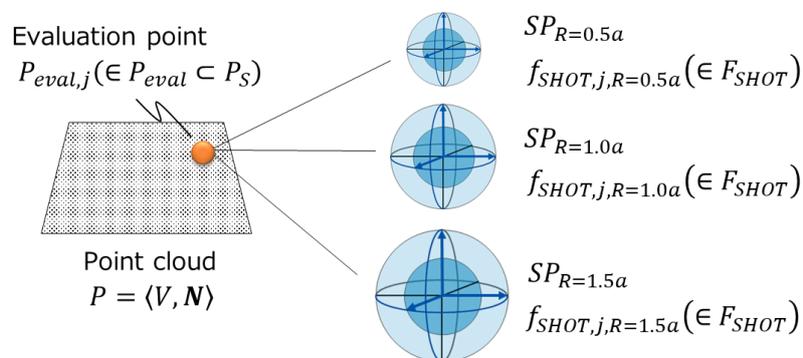


図 2-2-5 マルチスケール・サポート球による SHOT 特徴量

2-2-3 STEP3：キーポイントの選択

キーポイントは，局所形状特徴量のマッチングに使用する目的で選択された主要なポイントのことであり，特徴形状を表現するポイントの中から独自

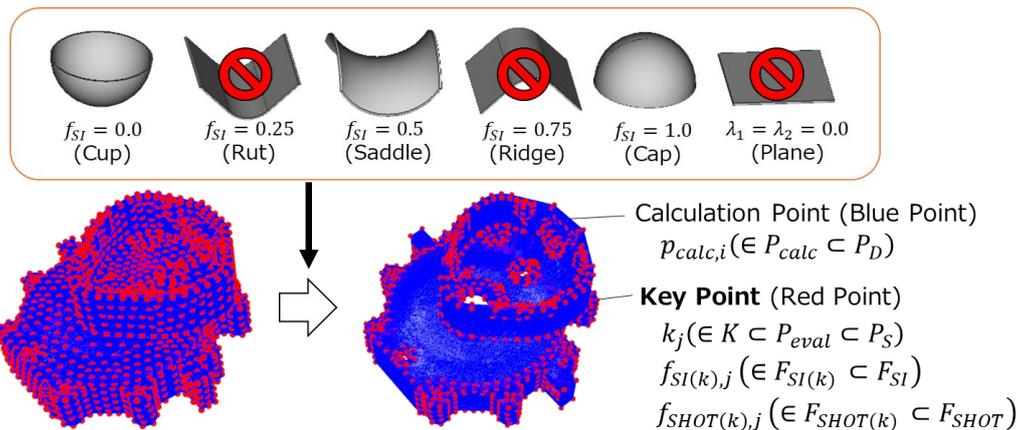


図 2-2-6 キーポイントの選択

性の高いポイントを選択することが有効である。独自性の高いポイントを一ポイントに採用することで、オブジェクト認識の処理時間が短縮されたという報告がある[Nagase13]. 本手法においても、処理時間の短縮を目的に、低密度三次元点群 P_S^T と P_S^R の各ポイント上に計算された SI 局所形状特徴量 $f_{SI,j}^T (\in F_{SI}^T)$ と $f_{SI,m}^R (\in F_{SI}^R)$ を用いて、独自性の高いキーポイント点群 $K^T (\subset P_S^T)$ と $K^R (\subset P_S^R)$ を選択的に作成する。

独自性の高いポイントは、2つ以上の面が合流する部位や曲面が複雑に入り組む部位に存在すると考えられ、局所的には、三次元曲面形状になると考えられる。したがって、図 2-2-3 に示す形状タイプの内、可展面である Rut, Ridge, Plane が独自性の高いポイントになる可能性は低い。したがって、SI 局所形状特徴量 $f_{SI,j}^T$ と $f_{SI,m}^R$ により Rut 形状又は Ridge 形状と判定されたポイント、及び最大主曲率 λ_1 と最小主曲率 λ_2 で Plan 形状と判定されたポイントを除外し、それ以外のポイントをキーポイントとすることで、図 2-2-6 にあるように、独自性の高いキーポイント点群 $K^T (\subset P_S^T)$ と $K^R (\subset P_S^R)$ を作成する。

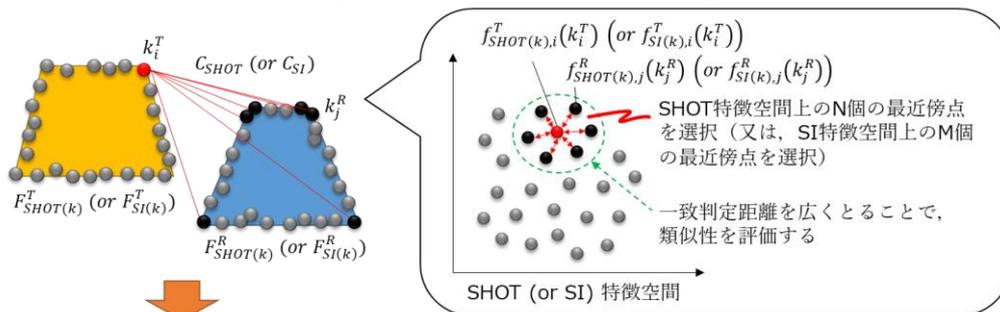
STEP3 では、入力 CAD モデル及び参照特徴形状 CAD モデルのキーポイントをそれぞれ $K^T (\subset P_S^T)$, $K^R (\subset P_S^R)$ として作成し、キーポイント上の SI 及び SHOT 局所形状特徴量を $F_{SI(k)}^T (\subset F_{SI}^T)$, $F_{SHOT(k)}^T (\subset F_{SHOT}^T)$, $F_{SI(k)}^R (\subset F_{SI}^R)$, $F_{SHOT(k)}^R (\subset F_{SHOT}^R)$ としてそれぞれ整理する。

2-2-4 STEP4：類似キーポイントペアセットの作成

ここでは、図 2-2-7 にあるように、入力 CAD モデルと参照特徴形状 CAD モデルのそれぞれのキーポイントの中から、互いに類似した局所形状特徴量を持つキーポイントを発見し、類似キーポイントペアとする。これにより、参照特徴形状の局所形状に類似する入力 CAD モデル上の局所形状部位が抽出されることになる。

はじめに、入力 CAD モデル上のキーポイント点群 K^T 上の局所形状特徴量 $f_{SI(k),i}^T (\in F_{SI(k)}^T)$ 及び $f_{SHOT(k),i}^T (\in F_{SHOT(k)}^T)$ から 1 つ取り出し、参照特徴形状 CAD モデルのキーポイント点群 K^R 上の $f_{SI(k),j}^R (\in F_{SI(k)}^R)$ 及び $f_{SHOT(k),j}^R (\in F_{SHOT(k)}^R)$ との特徴空間距離 $\|f_{SI(k),j}^R - f_{SI(k),i}^T\|$, $\|f_{SHOT(k),j}^R - f_{SHOT(k),i}^T\|$ を求め、距離が近い順に M 個の SI 類似キーポイントペア、N 個の SHOT 類似キーポイントペアを作成する。これを全ての $f_{SI(k),i}^T (\in F_{SI(k)}^T)$ 及び $f_{SHOT(k),i}^T (\in F_{SHOT(k)}^T)$ に対して実施し、SI 類似キーポイントペアセット $C_{SI} = \{(k_m^T, k_n^R)_q \mid q \in [1, M], k_m^T \in K^T\}$ と、SHOT 類似キーポイント

① SHOT 類似キーポイントペアセット C_{SHOT} と SI 類似キーポイントペアセット C_{SI} を生成する



② SHOT 類似キーポイントペアセット C_{SHOT} の内、キーポイント位置が SI 類似キーポイントペアセット C_{SI} と閾値 δ 内の距離にあるペアを残し、他を削除することで、類似キーポイントペアセット C_{SS} とする

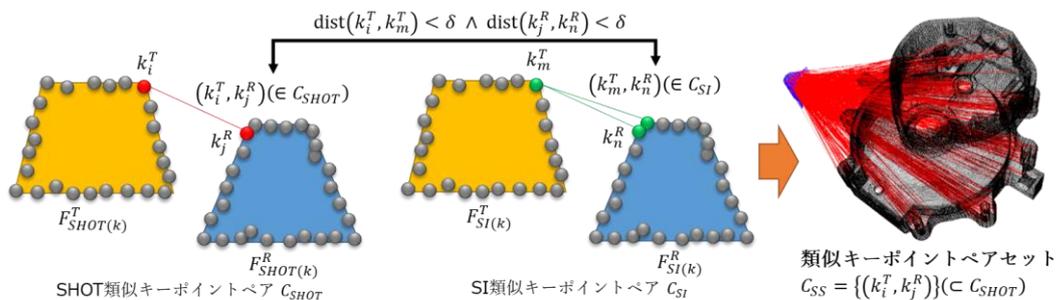


図 2-2-7 類似キーポイントペアセットの作成

トペアセット $C_{SHOT} = \{(k_i^T, k_j^R)_p \mid p \in [1, N], k_i^T \in K^T\}$ を作成する。

次に、SHOT 類似キーポイントペアセット C_{SHOT} の中から 1 つのペア $(k_i^T, k_j^R) (\in C_{SHOT})$ を取り出し、SI 類似キーポイントペアセット $(k_m^T, k_n^R) (\in C_{SI})$ と比較する。入力 CAD モデルのキーポイント同士である k_i^T と k_m^T のユークリッド距離 $\text{dist}(k_i^T, k_m^T)$ と、参照特徴形状 CAD モデルのキーポイント同士である k_j^R と k_n^R のユークリッド距離 $\text{dist}(k_j^R, k_n^R)$ を評価し、両者が共に閾値 δ 以内であれば、新しいキーポイントペアとして C_{SS} に格納する。この処理を C_{SHOT} 内の全ての類似キーポイントペアについて実施することで、類似キーポイントペアセット $C_{SS} = \{(k_i^T, k_j^R)\} (\subset C_{SHOT})$ を完成させる。

2-2-5 STEP5：近接する類似キーポイントのクラスタ化

類似キーポイントペアセット C_{SS} 内に含まれる入力 CAD モデル上のキーポイント $k_i^T (\in K_{SS}^T = \{k_i^T \mid (k_i^T, k_j^R) \in C_{SS}\})$ は、参照特徴形状と類似し且つ分散して配置された複数の特徴形状を示す場合がある。STEP6 では、参照特徴形状に対し 1 対 1 の類似特徴形状検索を行うため、これを独立した 1 つの類似特徴形状が含まれるよう分割する必要がある。したがって、図 2-2-8 にあるように、Euclidean Clustering [Rusu09-2] により、類似キーポイントペアセット C_{SS} を、近接する入力 CAD モデル上のキーポイント $k_i^T (\in K_{SS}^T)$ でクラスタ化し、近接類似キーポイントペアクラスタセット $C_{ECS} (= \{C_{EC,l}\} \subset C_{SS})$ を生成する。この

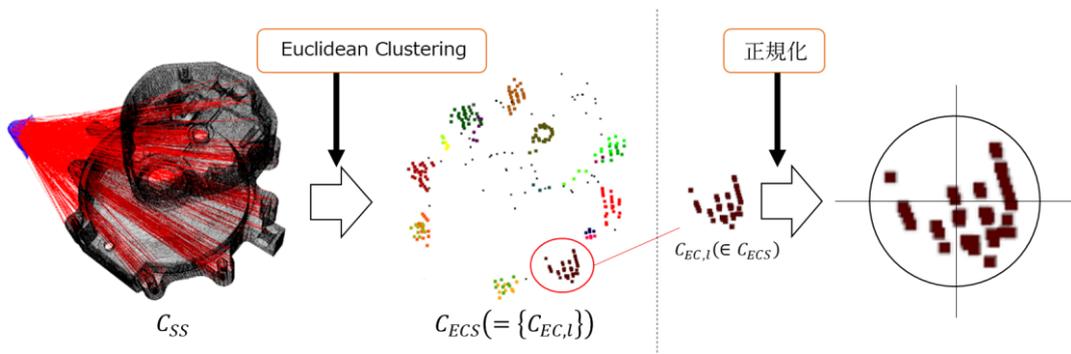


図 2-2-8 近接類似キーポイントペアクラスタセットの作成

処理により，各クラスタ $C_{EC,l} (\in C_{ECS})$ には，独立した1つの類似特徴形状を示すキーポイントのみが含まれる可能性が高くなる。

次に，ポイントの分布に依存する射影変換行列を用いた STEP6 の Random sample consensus (RANSAC) アルゴリズムの計算を安定させるため，各クラスタのポイント座標を平均が 0.0，標準偏差が 1.0 になるように正規化し，正規化座標系のキーポイント点群 $\tilde{K}_{EC,l}^T = \{\tilde{k}_i^T | (\tilde{k}_i^T, \tilde{k}_j^R) \in C_{EC,l}\}$ 及び $\tilde{K}_{EC,l}^R = \{\tilde{k}_j^R | (\tilde{k}_i^T, \tilde{k}_j^R) \in C_{EC,l}\}$ を得る。

これらの処理により，自由度が高く難易度の高い射影変換関係による類似性評価を，1つの特徴形状が存在する可能性の高い近接類似キーポイントペアクラスタ毎に絞ることができ，また，クラスタ毎の正規化により射影変換行列の計算を安定させることができるため，STEP6 の RANSAC アルゴリズムの処理効率を高めることが可能になる。

2-2-6 STEP6 : RANSAC による類似特徴形状抽出

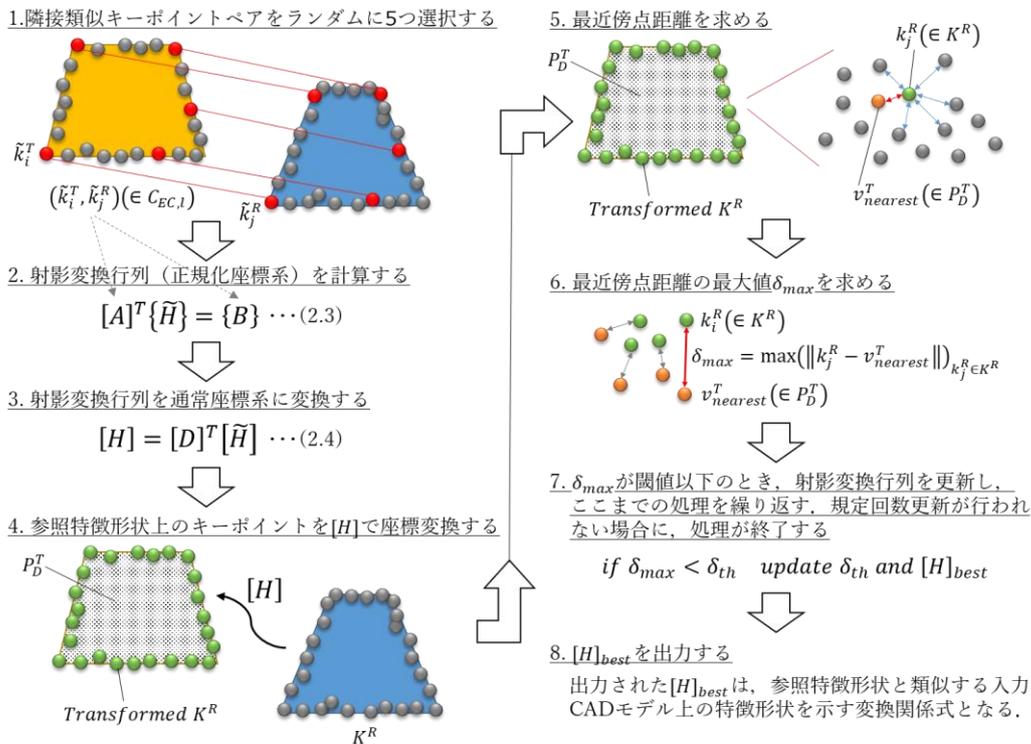


図 2-2-9 RANSAC による類似特徴形状抽出アルゴリズム

ここでは、隣接類似キーポイントペアクラスタ $C_{EC,l} (\in C_{ECS})$ を 1 つずつ取り出し、RANSAC を用いたアルゴリズムにより射影変換行列 $[H]$ を推定することで、最終的に、参照特徴形状と類似した全ての特徴形状を入力 CAD モデルの形状上に発見する。処理手順を図 2-2-9 及び以下に示す。

STEP6 の処理手順

1. 1 つの隣接類似キーポイントペアクラスタ $C_{EC,l}$ を取り出し、隣接類似キーポイントペアをランダムに 5 つ選択する。
2. 選択された隣接類似キーポイントペア $c_{k5} = \{(\tilde{k}_i^T, \tilde{k}_j^R)\} (\subset C_{EC,l})$ を使い射影変換行列 $[\tilde{H}]$ を求める。ここで、 c_{k5} のキーポイント座標値を基に計算された $[\tilde{H}]$ は、正規化座標系における射影変換行列である。
3. 得られた射影変換行列 $[\tilde{H}]$ を正規化座標系から通常座標系の射影変換行列 $[H]$ に変換する。
4. 得られた射影変換行列 $[H]$ を用いて、参照特徴形状のキーポイント点群 K^R を $[H]$ で座標変換する。
5. 射影変換後の各ポイントに対して、入力 CAD モデル上の高密度三次元点群 P_D^T の中から最近傍点を探索し、その距離を求める。
6. 最近傍点距離の中から、その最大値を求める。
7. 最近傍点距離の最大値が、保存された閾値よりも小さい場合には、その閾値と保存している射影変換行列 $[H]_{best}$ を更新する。ここまでの手順 1~7 の処理を繰り返す。そして、規定回数繰り返しても更新処理が行わない場合に処理を終了する。
8. 最終的に得られた射影変換行列 $[H]_{best}$ を出力する。これが、参照特徴形状に類似した入力 CAD モデル上の特徴形状を示す変換関係式となる。ここまでの処理を C_{ECS} 内の全ての隣接類似キーポイントペアクラスタ $C_{EC,l} (\in C_{ECS})$ に対して実行する。最終的に、1 つの参照特

微形状に対し，入力 CAD モデル形状上にある全ての類似特徴形状を抽出することができる．

射影変換行列 $[\tilde{H}]$ の各成分は，以下の式 2.2 に示す関係式を用いて整理した式 2.3 を LU 分解で求める．ここで，式 2.2 の $[\tilde{H}] = [\tilde{h}_{ij}]$ は， $\tilde{h}_{44} = 1$ とした 4×4 行列， $\{\tilde{Q}^R\}$ と $\{\tilde{Q}^T\}$ は，キーポイント $\{\tilde{k}_i^T | (\tilde{k}_i^T, \tilde{k}_j^R) \in c_{k5}\}$ と $\{\tilde{k}_j^R | (\tilde{k}_i^T, \tilde{k}_j^R) \in c_{k5}\}$ の同次座標， w は， $[\tilde{H}]\{\tilde{Q}^R\}$ の 4 番目の成分，つまり， $w = \sum_{i=1}^4 \tilde{h}_{4,i} \tilde{q}_i^R$ である．式 2.3 の $\{H\}$ は，式 2.2 の関係式を $[\tilde{H}]$ の各成分について整理し，自明となる 16 番目の成分 ($[\tilde{H}]$ の 4 行 4 列目の要素) を除くことで得られる 15×1 の列ベクトルであり，同様にして得られる $[A]$ と $\{B\}$ は， 15×15 行列， 15×1 列ベクトルである．

$$\frac{1}{w} [\tilde{H}]\{\tilde{Q}^R\} - \{\tilde{Q}^T\} = \{0\}, \quad (2.2)$$

$$[A]^T \{H\} = \{B\}, \quad (2.3)$$

また，射影変換行列 $[\tilde{H}]$ の成分ベクトル $\{H\}$ を求める際に使用されるキーポイント座標値は正規化されているため，得られた $[\tilde{H}]$ は，正規化された座標系での射影変換行列である．そのため，以下の式 2.4 を用いて，参照特徴形状を入力 CAD モデル形状上へ射影変換するための通常座標系における射影変換行列を求める．ここで， $[H]$ と $[\tilde{H}]$ は，通常座標系と正規化座標系の射影変換行列であり， $[D]$ は，正規化座標系から通常座標系への変換行列である．

$$[H] = [D]^T [\tilde{H}] \quad (2.4)$$

式 2.4 により得られた射影変換行列 $[H]$ を用いて，参照特徴形状のキーポイント点群 K^R を座標変換し，入力 CAD モデル上の高密度三次元点群 P_D^T との最近傍点距離で形状の一致を評価する．一致評価では，最近傍点 $v_{D,nearest}^T (\in P_D^T)$ を k 近傍法により探索し，その距離を $\delta = \|k_j^R - v_{D,nearest}^T\|$ で評価する．さらに，参照特徴形状のキーポイント点群 K^R に対する P_D^T の最近傍点距離 δ の最大値 $\delta_{max} = \max(\|k_j^R - v_{nearest}^T\|)_{k_j^R \in K^R}$ を求め，閾値 δ_{th} 以下 ($\delta_{max} < \delta_{th}$) になるまで計算を繰り返す．閾値 δ_{th} を満たした場合に δ_{th} を δ_{max} で更新し，更新時の $[H]$ で $[H]_{best}$ を更

新する。この閾値 δ_{th} の更新が、規定回数の繰り返し処理の間に 1 度も行われな
い場合に計算が終了する。そして、最終的に得られた $[H]_{best}$ が、射影変換行列の
最良解となり、参照特徴形状と入力 CAD モデル上の類似特徴形状の変換関
係式となる。

2-3 検証実験

ここでは、開発した類似特徴形状抽出アルゴリズムの有効性を以下の検証実験によって確認する。

検証実験内容

- ① 単体の類似特徴形状の抽出実験（2-3-1 節）
- ② 互いに独立して配置された複数の類似特徴形状の抽出実験（2-3-2 節）
- ③ 滑らかに接続された単体の類似特徴形状の抽出実験（2-3-3 節）
- ④ 滑らかに接続された複数の類似特徴形状の抽出実験（2-3-4 節）

2-3-1 検証実験①：単体の類似特徴形状の抽出実験

類似形状抽出の基本的な動作を確認する目的で、単体のリブ形状を参照特徴形状とし、参照特徴形状を変形させた形状を入力 CAD モデル（図 2-3-1）として検証実験を行った。参照特徴形状からの変形は、等方スケール変換、直交異方スケール変換、射影変換の 3 種類とし、直交異方スケール変換については、長さ方向、高さ方向、幅方向それぞれを変形させ、全 5 パターンの入力 CAD モデルを用いた。また、表 2-3-1 に使用したパラメータを示す。

その結果、図 2-3-2 に示すように、全ての変形ケースで特徴形状抽出に成功し、開発した類似特徴形状抽出アルゴリズムの正常動作が確認できた。図において一致線が交差している結果は、リブ形状が対称形状であり反転して認識されたためであり、正常に認識された結果である。また、完全一致形状の抽出を目的に設計された SHOT に対し、一致判定閾値の調整や、マルチスケール・サポート球によるスケール依存の軽減により、類似形状の抽出が可能であることが示された。等方スケール変換及び直交異方スケール変換では、1.8 倍の変形まで正常に動作することが確認することができたが、これは、

パラメータの最適化や点群の高密度化などにより、更なる改善が見込める。
 また、参照特徴形状をデータベースに追加登録することで、抽出可能な形状
 範囲を容易に拡張できるため、開発した類似特徴形状認識アルゴリズムの基
 本性能は十分であると判断した。

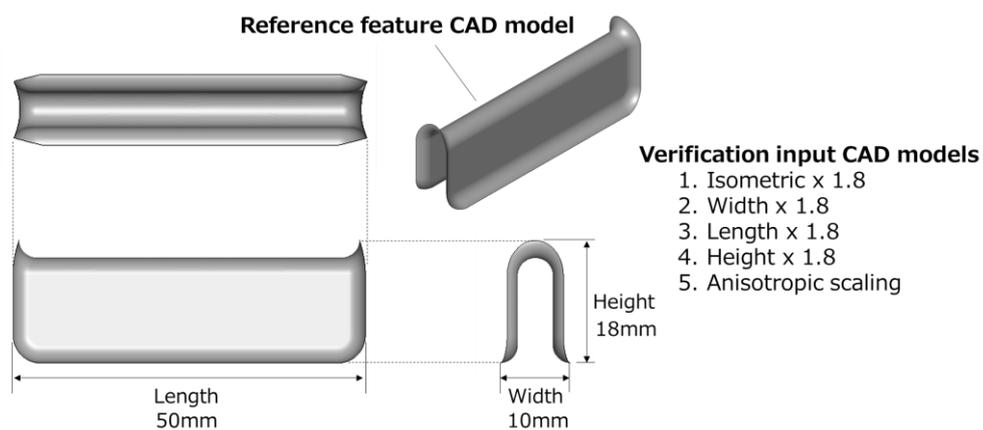


図 2-3-1 検証実験①：検証用モデル

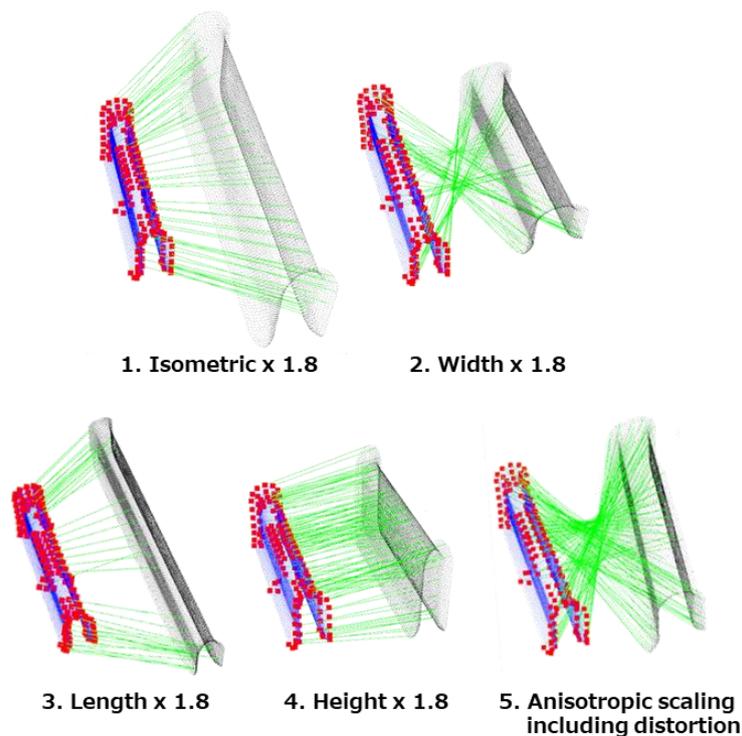


図 2-3-2 検証実験①：特徴形状抽出結果

表 2-3-1 検証実験①：パラメータ設定情報

パラメータ		設定値	
STEP1		参照特徴形状	入力 CAD モデル
低密度点群	ポイント間距離	10mm	10mm
	ポイント数	51	51
高密度点群	ポイント間距離	0.1mm	0.1mm
	ポイント数	192456	192456
STEP2		参照特徴形状	入力 CAD モデル
SHOT	サポート球半径	1～2mm	1～2mm
	サポート球の数	2	2
SI	サポート球半径	1～2mm	1～2mm
	サポート球の数	2	2
STEP3		参照特徴形状	入力 CAD モデル
SI	Rut, Ridge 判定	0.0001	0.0001
	平面判定	0.001	0.001
STEP4			
SHOT	類似マッチング閾値	0.25	
	類似キーポイントペア抽出数	20	
SI	類似マッチング閾値	0.0001	
	類似キーポイントペア抽出数	20	
マージ	一致判定距離	0.1mm	
STEP5			
クラスタ	クラスタ距離	-	
STEP6			
終了判定	更新無し反復回数（正常終了）	10000	
	解無し反復回数（異常終了）	1000000	
射影変換 行列	除外判定：体積膨張率幅	0.5～2.0	
	除外判定：スケール幅	0.5～2.0	
	除外判定：ひずみ上限	0.4	

2-3-2 検証実験②：互いに独立して配置された複数の類似特徴形状の抽出実験

次に、1つの入力 CAD モデル上から複数の類似特徴形状を抽出するための基本的な動作の確認を目的とし、複数のリブとボスを平板上に互いに独立して配置したモデルで検証実験を行った。入力 CAD モデルは、図 2-3-3 に示すように、形状が異なる類似したリブとボスをそれぞれ5つずつ平板上に配置したモデルであり、また、参照特徴形状は、入力 CAD モデル上の中央に

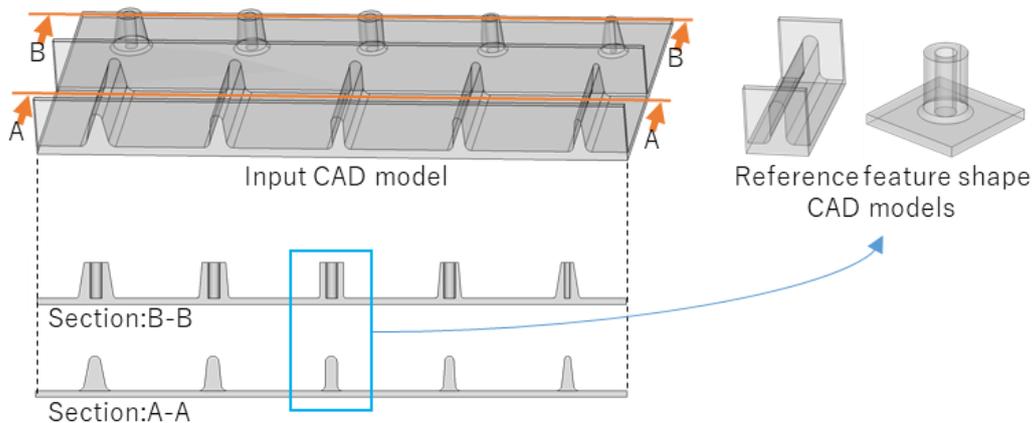


図 2-3-3 検証実験②：検証用モデル

配置されたリブとボスを切り出して使用した。

検証実験の結果、全てのリブの抽出に成功し、5つ中4つのボスの抽出に成功した。また、抽出成功にあたっては、いくつかのパラメータチューニングが必要であった。

射影変換は自由度が高く、大きく変形した形状の検出を許容してしまうため、射影変換行列[H]から算出される体積膨張率、スケール、ひずみに上限と下限を設けて、この条件を満たさない射影変換行列[H]を除外する必要がある。したがって、本検証実験においては、パラメータ調整の結果、体積膨張率は 0.2~5.0、スケールは 0.2~5.0、ひずみは 0.2 以下を最適値とした。

リブ形状に対しては、キーポイントの選択 (STEP3) において、独自性の高いキーポイントが多く残るよう SI 特徴量の閾値範囲を調整した。これは、リブ形状のように同一断面が一方向に続く形状では、変形した参照特徴形状がそのまま長手方向の部分領域に重なる場合があり、RANSAC による射影変換行列の推定計算が途中終了するためである。これを回避するため、独自性の高いキーポイントが多く残るよう SI 特徴量による除外判定閾値の幅を狭く設定し、STEP4 における類似キーポイントペアを増やすことで、部分領域を避けた特徴形状を抽出できる可能性を高めた。その結果、図 2-3-5 に示すように、本検証実験において、入力 CAD モデル上の全てのリブ形状を抽

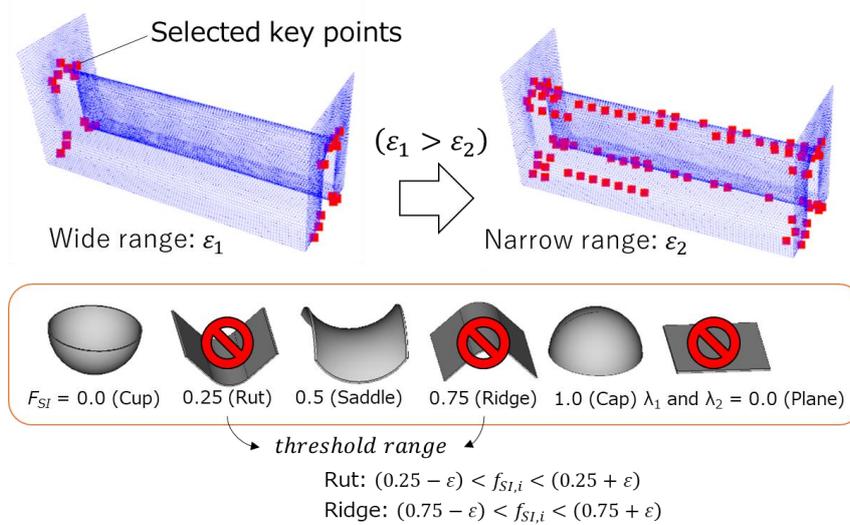


図 2-3-4 SI による判定閾値の調整

出することに成功した。

ボス形状は、軸対称形状であることに起因して抽出が困難であった。これは、軸対称形状では、周方向に分布するポイント上の SI 及び SHOT の特徴量が全て近い値となり、STEP4 で射影変換関係にない類似キーポイントペアが多く作成され、結果として、STEP6 の RANSAC で射影変換行列が一意に定まらないためである。また、ボス形状は、軸方向に同一断面が続く形状であり、リブ形状と同様に部分一致してしまう問題もある。これらを回避するためには、前述の射影変換行列の閾値調整及びキーポイント選択の閾値調整に加え、類似キーポイントペア間の位置座標空間上の平行度に閾値を設けて除外する処理などを加えることが有効と考えられる。しかし、実用上は、リブ付きボスなどを対象としており、今回のような完全な軸対称形状を対象とすることは少ないため、軸対称形状への対応は今後の課題として残すこととした。したがって、本検証実験においては、ボス側面の一部の領域に、目視で確認できない程度の小さな突起を追加して非軸対称形状としたうえで検証を行った。結果は、図 2-3-6 に示すように、5つのボスの内4つの抽出に成功し、1つが抽出できなかった。抽出できなかった原因は、図 2-3-7 に示す

ように、参照特徴形状との形状差異が大きいためであり、前述の射影変換行列の除外パラメータ調整や、参照特徴形状を変更することにより抽出可能である。

これらの検証で使用した最終的なパラメータ設定値を表 2-3-2 に示す。

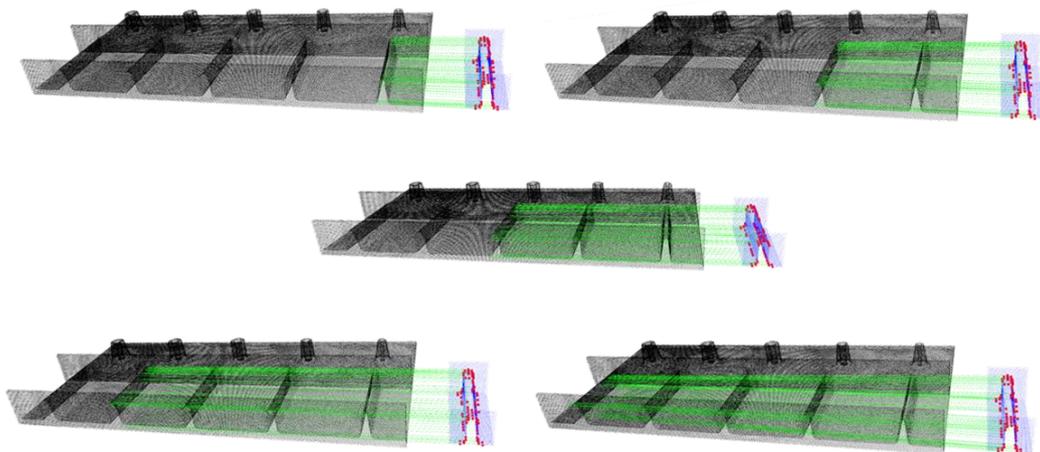


図 2-3-5 検証実験②：リブ形状による特徴形状抽出結果

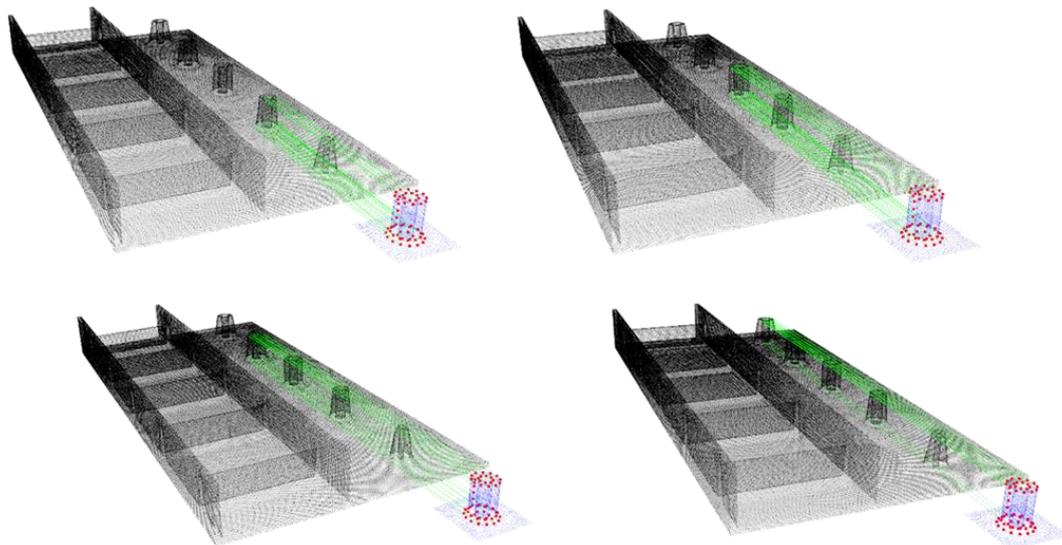


図 2-3-6 検証実験②：ボス形状による特徴形状抽出結果

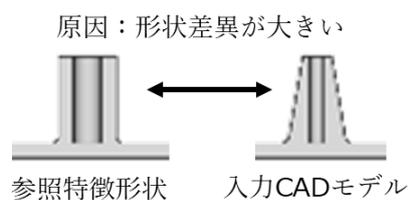


図 2-3-7 検証実験②：抽出できなかったボス形状

表 2-3-2 検証実験②：パラメータ設定情報（リブ）

パラメータ		設定値	
STEP1		参照特徴形状	入力 CAD モデル
低密度点群	ポイント間距離	5mm	5mm
	ポイント数	580	15122
高密度点群	ポイント間距離	1mm	1mm
	ポイント数	12433	366215
STEP2		参照特徴形状	入力 CAD モデル
SHOT	サポート球半径	3～6mm	3～6mm
	サポート球の数	5	5
SI	サポート球半径	3～6mm	3～6mm
	サポート球の数	5	5
STEP3		参照特徴形状	入力 CAD モデル
SI	Rut, Ridge 判定	1×10^{-9}	1×10^{-9}
	平面判定	1×10^{-8}	1×10^{-8}
STEP4			
SHOT	類似マッチング閾値	0.25	
	類似キーポイントペア抽出数	20	
SI	類似マッチング閾値	0.001	
	類似キーポイントペア抽出数	30	
マージ	一致判定距離	2mm	
STEP5			
クラスタ	クラスタ距離	50mm	
STEP6			
終了判定	更新無し反復回数（正常終了）	200	
	解無し反復回数（異常終了）	1000000	
射影変換 行列	除外判定：体積膨張率幅	0.5～5.0	
	除外判定：スケール幅	0.5～5.0	
	除外判定：ひずみ上限	0.2	

表 2-3-3 検証実験②：パラメータ設定情報（ボス）

パラメータ		設定値	
STEP1		参照特徴形状	入力 CAD モデル
低密度点群	ポイント間距離	5mm	5mm
	ポイント数	580	15122
高密度点群	ポイント間距離	1mm	1mm
	ポイント数	12433	366215
STEP2		参照特徴形状	入力 CAD モデル
SHOT	サポート球半径	1.5～3mm	1.5～3mm
	サポート球の数	5	5
SI	サポート球半径	1.5～3mm	1.5～3mm
	サポート球の数	5	5
STEP3		参照特徴形状	入力 CAD モデル
SI	Rut, Ridge 判定	1×10^{-3}	1×10^{-3}
	平面判定	1×10^{-2}	1×10^{-2}
STEP4			
SHOT	類似マッチング閾値	0.25	
	類似キーポイントペア抽出数	30	
SI	類似マッチング閾値	0.001	
	類似キーポイントペア抽出数	30	
マージ	一致判定距離	0.5mm	
STEP5			
クラスタ	クラスタ距離	50mm	
STEP6			
終了判定	更新無し反復回数（正常終了）	200	
	解無し反復回数（異常終了）	1000000	
射影変換 行列	除外判定：体積膨張率幅	0.5～5.0	
	除外判定：スケール幅	0.5～5.0	
	除外判定：ひずみ上限	0.2	

2-3-3 検証実験③：滑らかに接続された単体の類似特徴形状の抽出実験

ここでは、他の形状と接続された比較的複雑な類似特徴形状を抽出する、より実用に近いケースの動作確認を目的として検証実験を行った。図 2-3-8 に示す部品形状を入力 CAD モデルとし、その一部を切り出した部分形状を参照特徴形状とした。また、変形形状の抽出性能を確認するため、入力 CAD モデルと同サイズの参照特徴形状の他、異方直交変形させた 2 つのモデルを

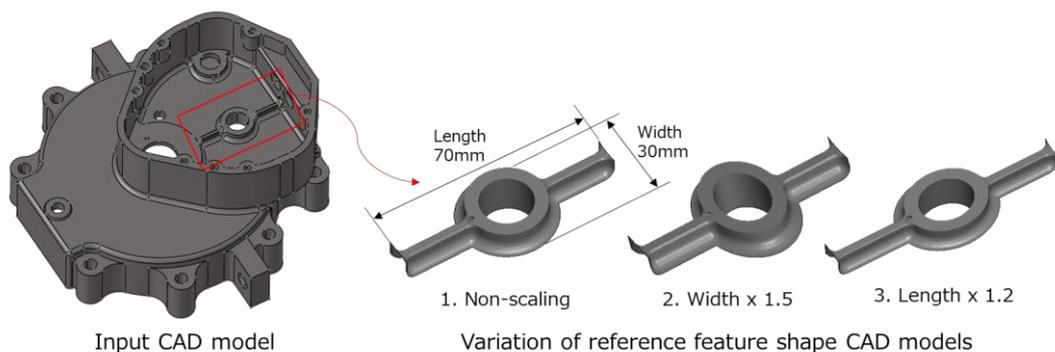


図 2-3-8 検証実験③：検証用モデル

用意した。表 2-3-4 に使用したパラメータを示す。

検証結果は、図 2-3-9 に示すように正常に特徴形状が抽出された。ただし、直交異方スケール変換形状における抽出可能なスケール範囲が変形方向により異なる。幅方向は 1.5 倍、長手方向は 1.2 倍までが抽出可能であった。これは、複雑な形状では、許容される変形範囲が狭くなる可能性を示している。これを回避するためには、SI 及び SHOT 形状記述子の特徴量マッチングの閾値をさらに広げることや、射影変換行列の除外パラメータを調整することなどの対策が考えられる。しかし、複雑な形状の場合は特に、参照特徴形状をデータベースに追加登録の方が容易且つ確実であり、本手法の基本コンセプトとも合致する。

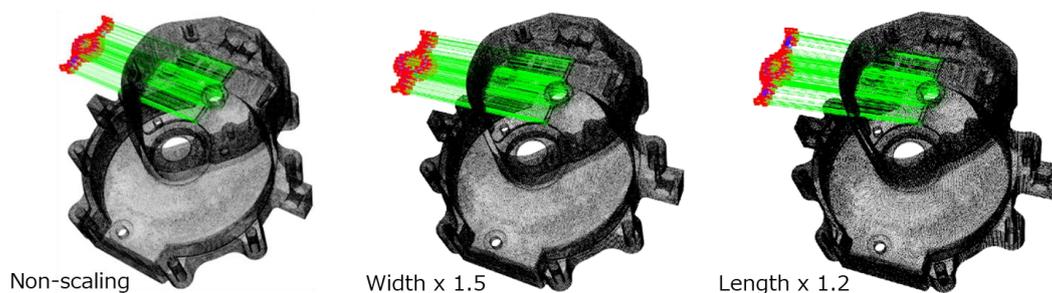


図 2-3-9 検証実験③：特徴形状抽出結果

表 2-3-4 検証実験③：パラメータ設定情報

パラメータ		設定値	
STEP1		参照特徴形状	入力 CAD モデル
低密度点群	ポイント間距離	4mm	10mm
	ポイント数	209	3587
高密度点群	ポイント間距離	1mm	1mm
	ポイント数	2844	177940
STEP2		参照特徴形状	入力 CAD モデル
SHOT	サポート球半径	3～6mm	3～6mm
	サポート球の数	5	5
SI	サポート球半径	3～6mm	3～6mm
	サポート球の数	5	5
STEP3		参照特徴形状	入力 CAD モデル
SI	Rut, Ridge 判定	1×10^{-9}	1×10^{-9}
	平面判定	1×10^{-8}	1×10^{-8}
STEP4			
SHOT	類似マッチング閾値	0.25	
	類似キーポイントペア抽出数	20	
SI	類似マッチング閾値	0.001	
	類似キーポイントペア抽出数	20	
マージ	一致判定距離	2mm	
STEP5			
クラスタ	クラスタ距離	50mm	
STEP6			
終了判定	更新無し反復回数（正常終了）	200	
	解無し反復回数（異常終了）	100000	
射影変換 行列	除外判定：体積膨張率幅	0.5～2.0	
	除外判定：スケール幅	0.5～10.0	
	除外判定：ひずみ上限	0.4	

2-3-4 検証実験④：滑らかに接続された複数の類似特徴形状の抽出実験

検証実験③と同様に、より実用に近い類似特徴形状抽出の動作確認を目的に、複数の類似特徴形状を抽出する検証実験を行った。図 2-3-10 に示す部品形状を入力 CAD モデルとし、その一部を切り出した部分形状を参照特徴形状とした。これにより、入力 CAD モデル上の類似形状又は一致形状を 8 カ所抽出する。使用したパラメータを表 2-3-5 に示す。

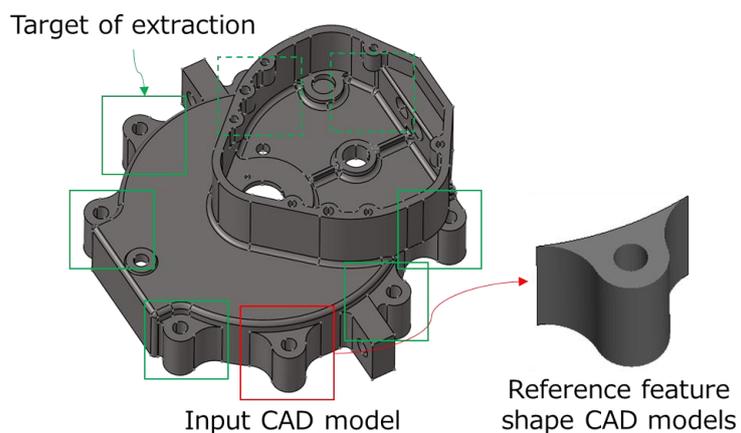


図 2-3-10 検証実験④：検証用モデル

検証実験の結果，図 2-3-11 に示すように，8 カ所中 6 カ所の類似特徴形状の抽出に成功した．残りの 2 カ所が抽出できていない原因は，参照特徴形状との形状差異が大きく，同一参照特徴形状で抽出できる変形状範囲を超えているためと考えられる（図 2-3-12）．参照特徴形状を追加することで，これらの抽出が可能になる．第 4 章で後述する FE メッシュをマッピングする検証において，参照特徴形状を追加することで，残りの 2 カ所の抽出に成功している．

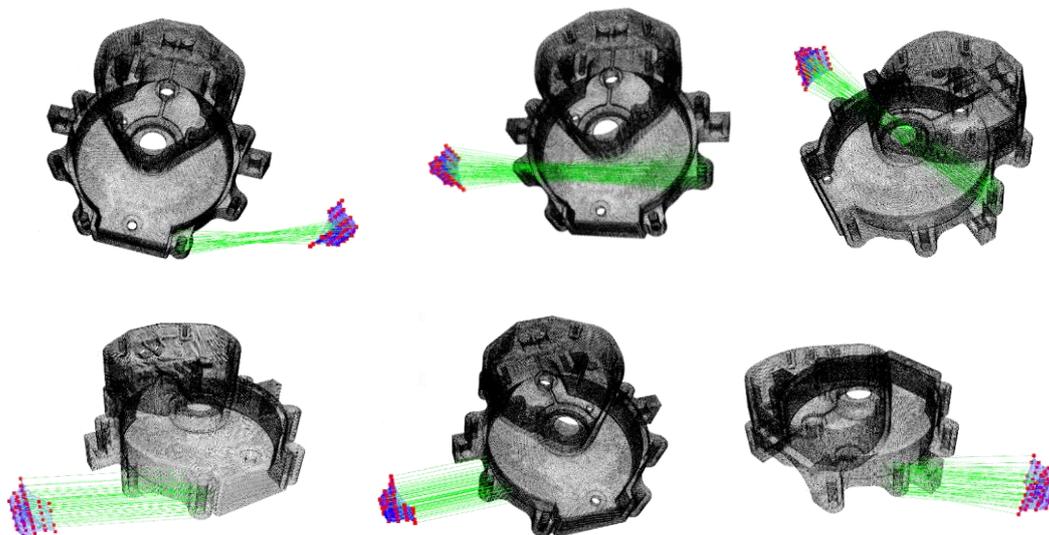


図 2-3-11 検証実験④：特徴形状抽出結果

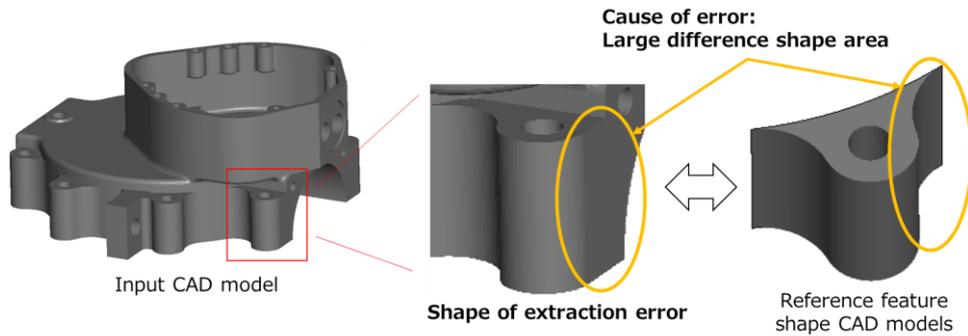


図 2-3-12 検証実験④：抽出できていない特徴形状

表 2-3-5 検証実験④：パラメータ設定情報

パラメータ		設定値	
STEP1		参照特徴形状	入力 CAD モデル
低密度点群	ポイント間距離	8mm	10mm
	ポイント数	70	3587
高密度点群	ポイント間距離	1mm	1mm
	ポイント数	4270	177940
STEP2		参照特徴形状	入力 CAD モデル
SHOT	サポート球半径	3～6mm	3～6mm
	サポート球の数	5	5
SI	サポート球半径	3～6mm	3～6mm
	サポート球の数	5	5
STEP3		参照特徴形状	入力 CAD モデル
SI	Rut, Ridge 判定	1×10^{-9}	1×10^{-9}
	平面判定	1×10^{-8}	1×10^{-8}
STEP4			
SHOT	類似マッチング閾値	0.25	
	類似キーポイントペア抽出数	10	
SI	類似マッチング閾値	0.001	
	類似キーポイントペア抽出数	10	
マージ	一致判定距離	2mm	
STEP5			
クラスタ	クラスタ距離	10mm	
STEP6			
終了判定	更新無し反復回数（正常終了）	200	
	解無し反復回数（異常終了）	100000	
射影変換 行列	除外判定：体積膨張率幅	0.2～10.0	
	除外判定：スケール幅	0.2～10.0	
	除外判定：ひずみ上限	0.4	

一方、表 2-3-6 に示すように、本検証の処理時間は約 39 分であった。内訳は、前半フェーズ (STEP 1~3) である参照特徴形状と入力 CAD モデルを局所形状記述子に変換する処理フェーズに約 4 分、後半フェーズ (STEP 4~6) である入力 CAD モデル上の類似特徴形状を抽出する処理フェーズに約 35 分。処理時間が大きい原因は、今回、特徴形状を確実に抽出するため、マルチスケール・サポート球を、参照特徴形状用に 5 つ、入力 CAD モデル形状用に 5 つとして多めに設定したこと、また、RANSAC で解が得られない場合の最大反復回数を大きくしていることにある。したがって、類似キーポイントペアセットを作成する際には、1 カ所につき総当たりで計 25 回のマッチング判定処理が必要になり、また、隣接類似キーポイントペアクラスタが 525 クラスタと増大し、さらに、解が得られないクラスタで多くの反復が必要になり、処理時間がかかっている。しかし、1 クラスタあたりの処理時間は平均 4 秒であり、これを RANSAC 反復数 1 回分と仮定して、正解探索時の RANSAC 反復回数 4 回とし、8 カ所の類似特徴形状を抽出するとした場合、後半フェーズで約 2 分となる。したがって、最短で前半後半合わせて約 6 分の処理時間になる。

表 2-3-6 処理時間

形状記述子への変換 (STEP1~3)	類似特徴形状の抽出 (STEP4~6)	合計
4 分	2~35 分	6~39 分
(実行環境) CPU : Intel Core i7-6600U @2.6GHz x 2Core, CPU Memory : 16GB, OS : Windows10 64bit		

2-4 まとめと今後の課題

本研究では、製品形状 CAD モデルを入力とし、特徴形状毎に規定された仕様に適合した FE メッシュをマッピング方式により自動生成することを前提とした、三次元点群と形状記述子を用いた類似特徴形状認識技術を開発し、その有効性を示した。

本章で開発した技術の成果を以下にまとめる。

(1) 参照特徴形状を用いた統一的且つ拡張性のある類似特徴形状抽出手法の実現

データベース上に登録された参照特徴形状 CAD モデルの局所形状特徴量と、入力 CAD モデルの局所形状特徴量とのマッチングによる類似特徴形状抽出手法を開発した。これにより、参照特徴形状のデータベース追加登録のみによる抽出可能特徴形状バリエーションの容易な拡充を可能とし、特徴形状バリエーションの違いに依存せず統一的且つ拡張性の高いアルゴリズムによる動作を実現した。

(2) RANSAC を用いた非剛体且つパラメトリックな変形関係の類似特徴形状抽出手法の実現

局所形状特徴量マッチングの結果に基づき、RANSAC を用いて射影変換行列の推定を行うという独自アルゴリズムによる類似特徴形状抽出技術を開発した。これにより、パラメトリックな変形範囲において、等方スケーリング変換関係、直交異方スケーリング変換関係を含む射影変換関係にある類似特徴形状の抽出を可能にし、複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状 CAD モデルに対しての頑健動作を実現した。

(3) 三次元点群と局所形状記述子 SHOT 及び SI を用いた離散的形状表現による類似特徴形状抽出手法の実現

CAD モデルから生成された三次元点群，及び三次元点群から生成された局所形状記述子を用いた離散的形状表現に基づく類似特徴形状抽出技術を開発した．CAD モデルに依存する位相構造や幾何表現形式を陽に持たない離散的形状表現を用いることで，CAD モデルの構成要素に依存しないアルゴリズムとし，複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状 CAD モデルに対しての頑健動作を実現した．

(4) 提案する類似特徴形状抽出手法の有効性を確認

本手法の有効性が 4 種類の検証実験，①単体の類似特徴形状の抽出実験，②独立して配置された複数の類似特徴形状の抽出実験，③滑らかに接続された単体の類似特徴形状の抽出実験，④滑らかに接続された複数の類似特徴形状の抽出実験により確認された．これらの検証実験により，等方スケール変換，直交異方スケール変換，射影変換の変形関係にある類似特徴形状が，実用上十分な範囲において抽出可能であることが示され，また，独立して配置された類似特徴形状を単体又は複数に関わらず抽出でき，さらに，滑らかに接続された特徴形状においても単体又は複数に関わらず抽出できることが示された．

今後の課題は以下 3 点であり，これらを解決することで，CAE モデル自動生成システムの実現が可能になるものと思われる．

(1) 同一断面が一方向に続く形状及び軸対称形状への対応

抽出が失敗する多くのケースは，参照特徴形状を追加登録することで抽出可能になるが，同一断面が一方向に続く形状の抽出にはパラメータの調整が必要であり，また，完全な軸対称形状の抽出は困難なまま

である。これらは射影変換行列計算の際の類似キーポイントペア選択に対して制約条件を設けることで回避できる可能性がある。

(2) CAD モデルから直接的に局所形状記述子を生成する手法の構築

現在のアルゴリズムでは、入力 CAD モデル又は参照特徴形状 CAD モデルから三角形メッシュを介して生成された法線付き三次元点群を用いて局所形状記述子を作成しているため、処理が複雑で時間がかかるうえ、点群密度に依存する局所形状記述子の特徴量計算のコントロールが容易ではない。入力 CAD モデルから直接的に局所形状記述子を作成できれば、高速化及び高精度化の可能性がある。

(3) 射影変換行列による FE メッシュのマッピング精度検証

後述する FE メッシュのマッピング検証実験において、本方式の FE メッシュ自動生成システムの実現性が確認されている。しかし、開発した類似特徴形状抽出手法で得られた参照特徴形状 CAD モデルと入力 CAD モデルとの関係を表す射影変換行列の精度評価は、本研究のスコープ外であり、現時点で詳細に検証されていない。マッピング方式 FE メッシュ自動生成システムでは、その射影変換行列を用いて、参照特徴形状に関連付く FE メッシュを入力 CAD モデル上にマッピングする必要があり、射影変換行列の精度が非常に重要となる、したがって、得られた射影変換行列により正確なマッピングを行うための詳細な検証は、今後の課題である。

第 3 章

三次元点群と深層学習を用いた

自由曲面特徴形状認識技術の開発

3-1 特徴とアルゴリズムの概要

本手法は、製品形状 CAD モデルを入力とし、特徴形状毎に規定された仕様に適合した FE メッシュを作成手順逐次実行方式で自動生成することを前提とした特徴形状認識技術である。また、従来手法での問題点を改善し、①PDQ 劣化部を含む CAD モデルや、②複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状 CAD モデルに対して頑健に動作し、さらに、③特徴形状タイプの違いに依存せず統一的で拡張性の高いアルゴリズムで動作する三次元特徴形状認識技術である。

これらを実現するため、入力 CAD モデルの位相構造や幾何表現形式などに依存しない離散的形状表現を採用しており、入力される製品形状 CAD モデルを高密度点群に変換して用いる。また、三次元点群深層学習ネットワークによる機械学習アプローチを採用し、特徴形状クラスと局所特徴領域の抽出を可能にしている。

しかし、深層学習アプローチで高い認識精度を得るためには、大量のトレーニングデータが必要となる。十分な量且つ適切な三次元形状モデルを確保することは困難であり、深層学習アプローチの大きな課題になっている。そこで本研究では、パラメトリック CAD でトレーニング用特徴形状 CAD モデルを効率的に大量生成することを前提とし、単体特徴形状毎の認識処理を行う独自の形状認識アルゴリズムを開発し、トレーニングデータの問題を改善している。

具体的には、入力された製品形状 CAD モデルを高密度点群に変換した後、Multi-Scale Bounding Box (MSBB) を用いて大小様々な点群サブセットを抽出し、分類ネットワークで各点群サブセットを特徴形状クラスに分類、Non-Maximum Suppression (NMS)を用いて推定確率の高い点群サブセットを抽出する。抽出された点群サブセットをセグメンテーションネットワークに入力し、局所特徴領域にセグメンテーション、最終的に入力 CAD モデル点群の各ポイントにラベル割付けした点群を出力する。

このような単体特徴形状毎に認識処理を行うアルゴリズムを開発したことで、パラメトリック CAD を活用し、形状パラメータ（例：高さ、幅、長さ等）から、トレーニングデータを効率的且つ大量に自動生成することを可能にした。

本手法のアルゴリズムは、図 3-1-1 にある 7つの STEP から構成されており、前半の STEP 1~4 は、トレーニングデータセット生成と深層学習ネットワーク構築のフェーズであり、後半の STEP 5~7 は、入力 CAD モデル上の特徴形状及び局所特徴領域を認識しラベル割付けするフェーズである。

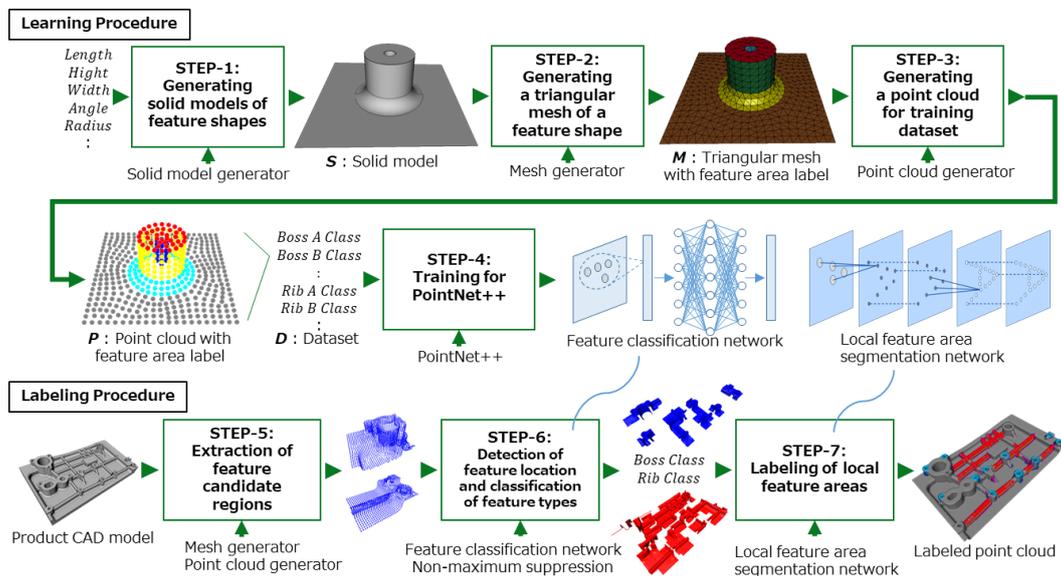


図 3-1-1 三次元点群と深層学習を用いた自由曲面特徴形状認識技術のアルゴリズムの概要

3-2 アルゴリズムの詳細

ここでは、図 3-1-1 の各 STEP における処理の詳細について述べる。

3-2-1 STEP1：パラメトリック CAD による特徴形状 CAD モデルの生成

ある特徴形状クラスの CAD モデル $S = \langle S_f, L_c, L_a \rangle$ のバリエーション $s_i (\in S)$ の大量生成を、形状パラメータ群 $F_{sp} (\in D^F)$ によるパラメトリック CAD で行い、特徴形状 CAD モデルデータセット $D^S = \{S\}$ を作成する。ここで、 L_c と L_a は、 S を構成する面分集合 S_f 内の各面分に割当てられた特徴形状クラスのラベル集合と局所特徴領域のラベル集合である。また、 $D^F = \{F_{sp}\}$ は、各特徴形状を生成するための形状パラメータ群 F_{sp} で構成される形状パラメータ集合であり、トレーニングデータセット生成のための入力データである。特徴形状 a に対する形状パラメータ群を $F_{sp(a)}$ で表し、その構成要素を、特徴形状 a の基本形状表現に必要な要素、たとえば、高さ、幅、長さ等とする。パラメトリック CAD で使用する特徴形状 a の基準 CAD モデルを $s_{0(a)} (\in S)$ とし、 $s_{0(a)}$ から $F_{sp(a)}$ の i 番目の要素 $f_{sp,i(a)} (\in F_{sp(a)})$ を用いて生成される特徴形状 CAD モデルを $s_{i(a)} (\in S)$ とする。ここで、 $f_{sp,i(a)}$ は、高さ=10mm、幅=5mm、長さ=50mm 等の具体的な数値となる。

図 3-2-1 に特徴形状 CAD モデルデータセットの生成イメージを示す。また、本研究では、エンジンなどの鋳造部品に一般的に見られる図 3-2-1 に示すようなリブとボスを認識対象の特徴形状クラスとしている。

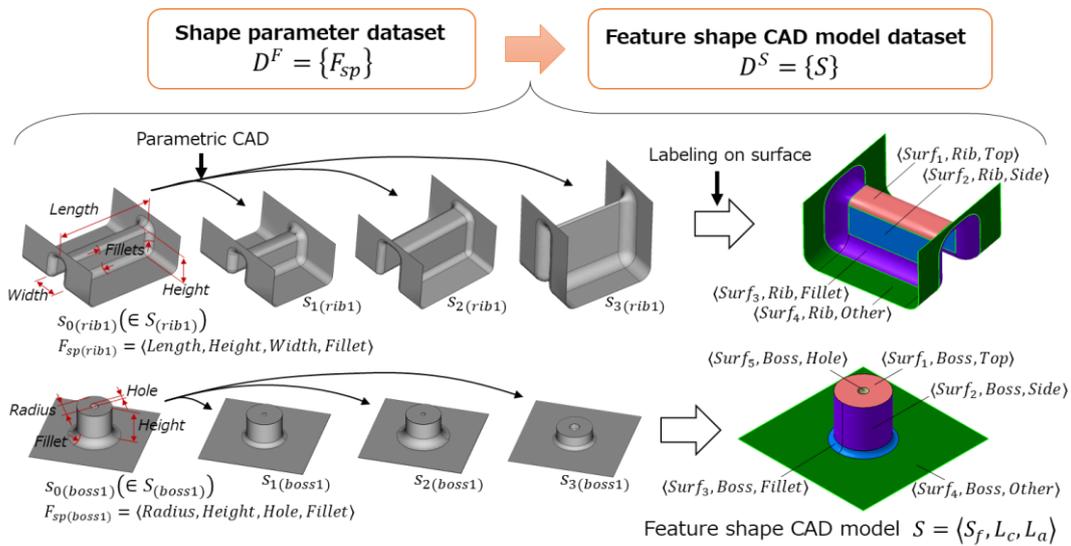


図 3-2-1 特徴形状 CAD モデルデータセットの生成

3-2-2 STEP2 : 三角形メッシュの生成

次に、特徴形状 CAD モデルデータセット $D^S = \{S\}$ から三角形メッシュデータセット $D^M = \{M\}$ を生成する。特徴形状 CAD モデル $S = \langle S_f, L_c, L_a \rangle$ の各面分上のラベル情報は、三角形メッシュ M の各頂点 V 上に引き継がれる。ただし、面分境界上にある頂点ではラベルが競合する。この場合、競合を回避するために一定のルールに従ってラベルを割付けるか、又は、メッシュを分割し同じ位置に複数のラベル付き頂点を重複して存在させる。点群密度が十分に高い場合には、どちらの方法でも認識精度に対する影響は極めて少ない。ここで、三角形メッシュ M は、図 3-2-2 に示すように、三角形メッシュ頂点 V と三角形メッシュ要素 T の集合から構成されており、 $M = \langle V, T, L_c, L_a \rangle$ で表す。

具体的な処理は、まず、商用 CAE プリソフトウェアの標準機能である三角形メッシュ生成機能を用いて、特徴形状 CAD モデル S から、 S の面分上に多数のサンプル頂点を発生させて三角形メッシュ M を生成し、次に、生成された各三角形メッシュ M の各頂点 $v_i (\in V)$ に対し、その頂点が位置する特徴形状 CAD モデル $S = \langle S_f, L_c, L_a \rangle$ の面分 $s_{f,j} (\in S_f)$ 上のラベル情報を割付ける。

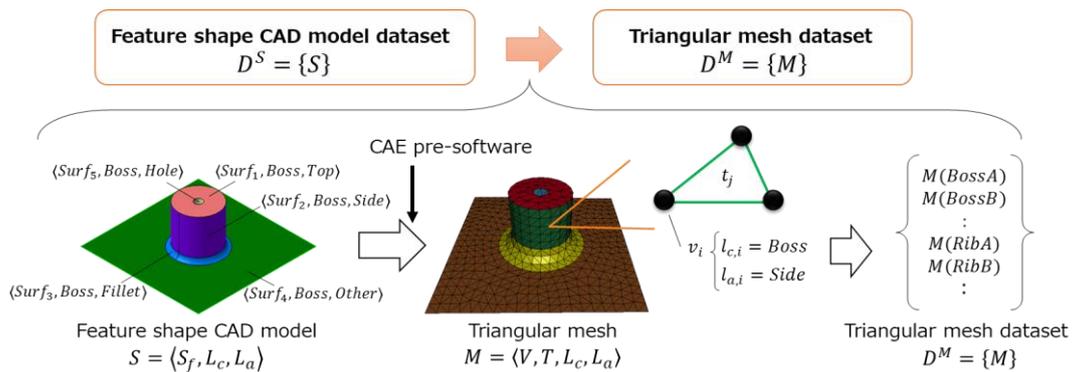


図 3-2-2 三角形メッシュデータセットの生成

3-2-3 STEP3 : 特徴形状点群トレーニングデータセットの生成

次に、三角形メッシュデータセット $D^M = \{M\}$ から特徴形状点群トレーニングデータセット $D^P = \{P\}$ を生成する。

図 3-2-3 に示すように、まず、三角形メッシュ M から頂点 V 上の法線ベクトル N を算出する。次に、特徴形状点群深層学習ネットワークのトレーニングデータとしての必要要件である位置とサイズの正規化を行う。三角形メッシュ M から頂点 V を取り出し、頂点 V の図心を原点に移動し、頂点 V を取り囲む Axis Aligned Bounding Box の最大軸長が 1.0 になるようサイズを調整する。その上で、原点を中心とした直径 1.0 の球の中に頂点 V が入るよう正規化する。また、正規化された頂点 V を Q として再定義する。最後に、点群 Q 、頂点 V 上 (= 点群 Q 上) の特徴形状クラスラベル L_c 及び局所特徴領域ラベル L_a 、算出した頂点 V 上 (= 点群 Q 上) の法線ベクトル N から、特徴形状点群 $P = \langle Q, N, L_c, L_a \rangle$ を作成する。

これらの処理を全ての三角形メッシュ $M (\in D^M)$ に対して行うことで、特徴形状点群トレーニングデータセット $D^P = \{P\}$ を得る。

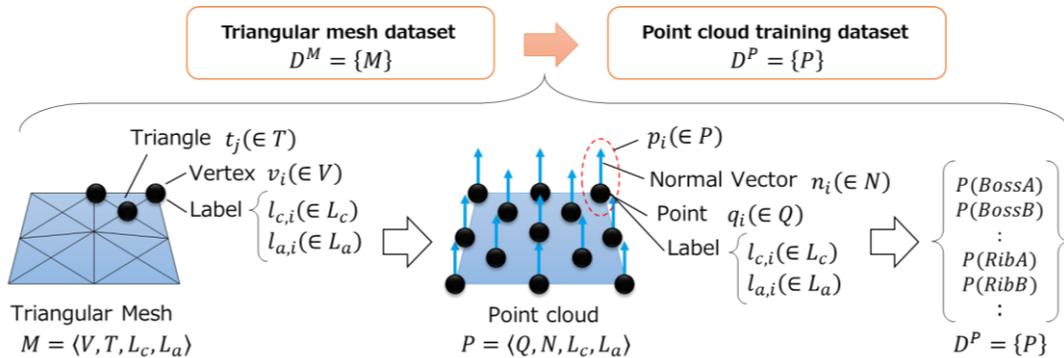


図 3-2-3 特徴形状点群トレーニングデータセットの生成

3-2-4 STEP4 : 深層学習ネットワークのトレーニング

ここでは、図 3-2-4 にあるように、深層学習ネットワークに PointNet++ [Qi17-2]を採用し、特徴形状点群トレーニングデータセット $D^P = \{P\}$ を用いて、特徴形状クラス分類ネットワーク W_{cls} 、及び局所特徴領域セグメンテーションネットワーク W_{seg} をトレーニングする。本手法では、これら 2つのネットワークを個別にトレーニングし、後述するように、まず、特徴形状クラス分類ネットワーク W_{cls} で特徴形状クラスを特定し、その後、局所特徴領域セグメンテーションネットワーク W_{seg} で局所特徴領域にセグメンテーションする。一方、PointNet++は、特徴形状クラス及び局所特徴領域を含めてトレーニングし、1つのネットワークによって特徴形状クラス分類と局所特徴領域セグメンテーションを行うことも可能である。しかし、両認識において高い精度を得るには、両認識に最適なデータセットを用意し、一括でトレーニングを行う必要がある。そのため、トレーニングに多くの時間が必要になるだけでなく、認識精度を高めるための個別のチューニングが困難となる。したがって、本手法は、効率的に認識精度を高めることを目的に、2つのネットワークを個別にトレーニングすることとした。

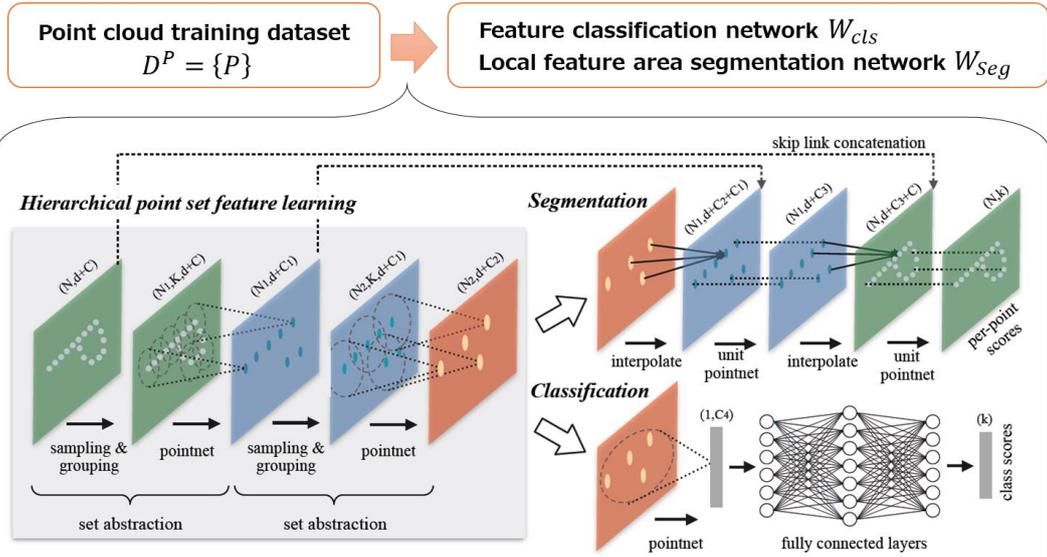


図 3-2-4 PointNet++に基づく深層学習ネットワークの
トレーニング [Qi17-2]

PointNet++は、三次元点群を直接使用し、分類やセグメンテーションを行うことが可能な階層構造型の深層学習ネットワークである。点群の順序や、回転、並行移動に対して不変であり、また、局所形状に対応可能であるという特徴を持つ。この特徴を実現するため、サンプリングレイヤー、グルーピングレイヤー、PointNet レイヤーで構成される抽象化レベルの階層を複数階層重ねた階層構造型ネットワークが採用されている。サンプリングレイヤーで、与えられたポイントに対し点群全体の中から最遠ポイントを選択する Farthest Point Sampling (FPS)を反復的に実行することで、点群全体を広範囲にカバーする重心ポイントを選択し、グルーピングレイヤーで、重心ポイント毎に特定半径内にある近傍ポイントを選択し、局所領域に対応するポイントサブセットを作成する。PointNet レイヤーでは、mini-PointNet を用いて、ポイントサブセット毎の局所領域パターンを特徴ベクトルにエンコードする。これらのレイヤーに基づき、入力された点群の局所領域を抽象化し、以降の階層毎に抽象化レベルを上げていく。この階層構造によって局所形状に対応できるネットワークを実現している。

また、オリジナルの PointNet++[Qi17-2]では、分類とセグメンテーションを一括処理で行うため、トレーニングモデルがオブジェクト全体になってしまう。本手法では、図 3-2-5 にあるように、個別の特徴形状を対象とし、特徴形状検出とセグメンテーションをそれぞれ実施するよう PointNet++を活用している。分類とセグメンテーションを個別の専用ネットワークにすることで、認識工程毎の精度向上チューニングが可能になり、また、単体特徴形状をトレーニングモデルとして形状パラメータから自動増幅することが可能になった。

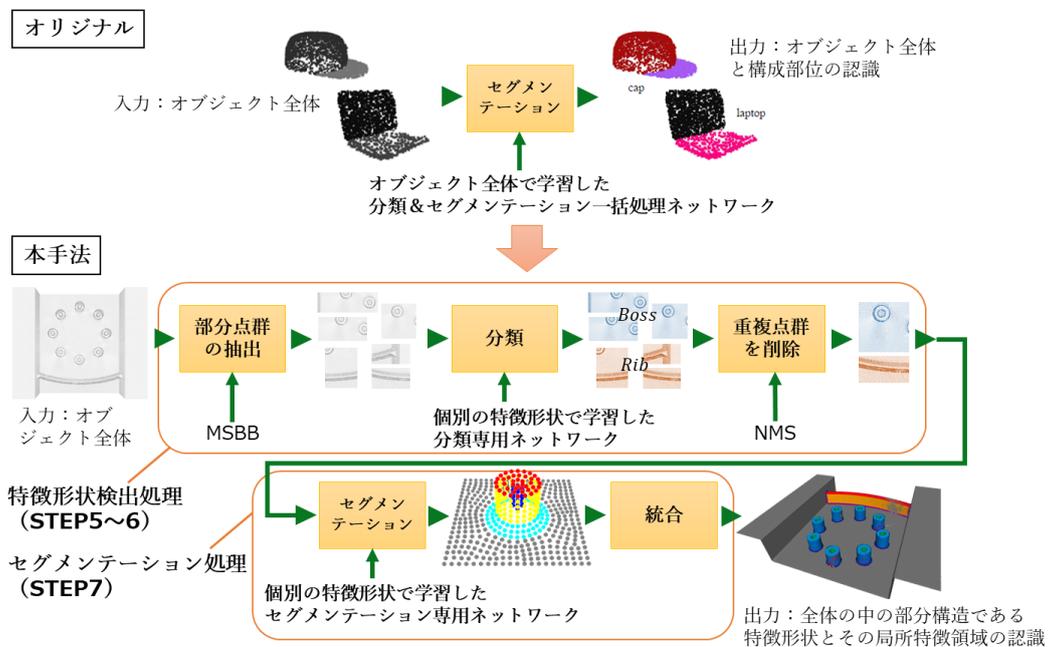


図 3-2-5 本手法における PointNet++の活用方法（後半処理の概要）

3-2-5 STEP5：入力 CAD モデル上の特徴形状候補領域の抽出

この STEP から後半フェーズであり、トレーニングした深層学習ネットワークを用いて、入力 CAD モデル上の特徴形状及び局所特徴領域を抽出する。

後半処理の概要を先の図 3-2-5 に示す。まず、入力 CAD モデルを STEP2～3 と同様に三角形メッシュを介して点群に変換し、入力点群を得る。そして、入力点群から複数の特徴形状候補領域の点群サブセットを抽出する。次に、抽出された点群サブセット毎に分類専用ネットワークを用いて特徴形状クラスに分類し、領域が重複する点群サブセットの中からクラス推定確率の高い点群サブセットを抽出する。抽出された点群サブセットをセグメンテーション専用ネットワークで局所特徴領域にセグメンテーションする。つまり、点群サブセット毎の各ポイントの特徴形状クラス及び局所特徴領域の推定値を算出する。最後に、点群サブセット毎に得られた各ポイントの推定値により、入力 CAD モデル点群の各ポイントのラベルを特定し出力点群を得る。

STEP5～6 の処理では、複数の特徴形状が含まれている入力 CAD モデルに対して特徴形状検出を行う。ここでは、画像処理で一般的に使用される物体検出手法と類似した手法を採用する。

STEP5 の具体的な処理は、図 3-2-6 にあるように、まず、入力 CAD モデル S^{IN} に対して STEP2～3 と同様の処理を行い、正規化した入力点群 $P^{IN} = \{p_i^{IN}\}$ を得る。次に、Multi-Scale Bounding Box (MSBB) を用いて、入力点群 P^{IN} の中から各 MBSS 内に含まれる点群をコピーした点群サブセット $\tilde{p}_j^{SS} = \{p_i^{IN} \mid p_i^{IN} \in P^{IN}, p_i^{IN} \in MBSS_j\}$ を生成する。そして、MSBB により生成された点群サブセット \tilde{p}^{SS} の内、ポイント数の閾値（下限 a と上限 b ）を満足しないものを削除する。つまり、この閾値を満たさない場合、その点群サブセットには特徴形状が含まれない又は複数あると判断し、以降の処理を行わないことと

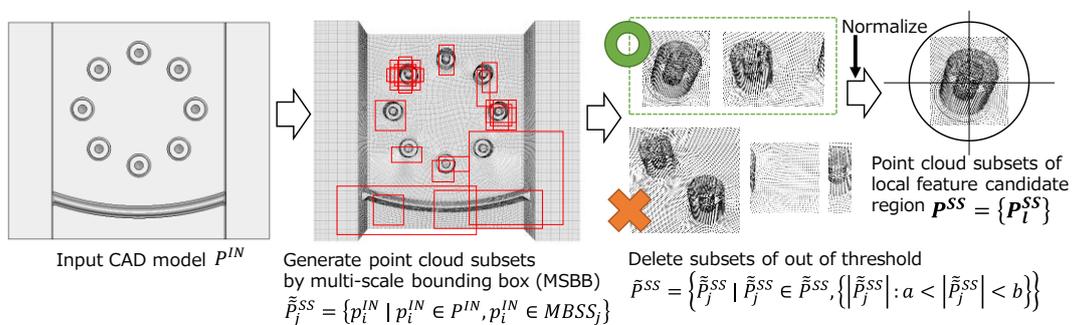


図 3-2-6 入力 CAD モデル上の特徴形状候補領域の抽出

する。これにより、特徴形状が1つだけ含まれる可能性のある点群サブセット $\tilde{P}^{SS} = \{\tilde{p}_j^{SS} \mid \tilde{p}_j^{SS} \in \tilde{P}^{SS}, \{|\tilde{p}_j^{SS}| : a < |\tilde{p}_j^{SS}| < b\}\}$ が得られる。最後に、特徴形状が含まれる可能性のある各点群サブセット $\tilde{P}_k^{SS} (\in \tilde{P}^{SS})$ を正規化し、特徴形状候補領域点群サブセット $P_l^{SS} (\in P^{SS})$ を得る。

ここで、MSBBは、画像認識に使用される Single-Shot multi-box Detector (SSD) [Limaye20][Liu16]におけるデフォルトボックス（パラメトリックに形状変更してボックス形状を生成するための基準となるボックス形状）を用いてバウンディングボックスとして生成したものであり、本手法においては、入力点群から点群サブセットを生成する目的にのみに使用する。MSBBを用いた点群サブセットの生成は、まず、図 3-2-7 に示すように、正規化された空間をいくつかのパターンで分割する。そして、各パターンの各領域において、デフォルトボックスを用いた複数のバウンディングボックス (MSBB) を生成する。最後に、各バウンディングボックス内に入る入力点群のポイントをコピーして取り出し、点群サブセットとする。MSBB の 1 つ 1 つの領域は互いに重複しているため、入力点群上のある 1 つのポイントが、複数の点群サブセットに重複して存在することになる。

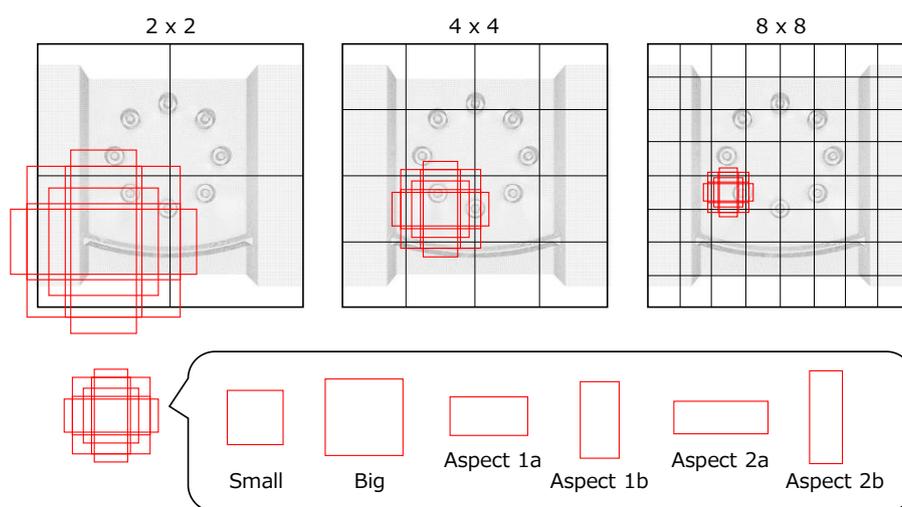


図 3-2-7 Multi-Scale Bounding Box (MSBB)

3-2-6 STEP6 : 特徴形状領域の検出と特徴形状クラスの特定

ここでは、STEP5 で生成した特徴形状候補領域点群サブセット $P_i^{SS} (\in P^{SS})$ を特徴形状クラス分類ネットワーク W_{cls} に入力し、得られる点群サブセット P_i^{SS} 毎のクラス推定確率 $\text{Pr}_{cls}(P_i^{SS})$ を用いて特徴形状領域の検出と特徴形状クラスの特定を行う。各点群サブセット P_i^{SS} は、図 3-2-7 に示す MSBB を用いて生成されており、領域が重なる点群サブセット $P_j^{SS} = \text{Overlap}(P_i^{SS})$ が他に存在する。そのため、図 3-2-8 にあるように、Non-Maximum Suppression (NMS) [Pham20] により、領域の重なりが多い点群サブセットグループ $P^{SSi_overlap} = \{P_j^{SS} \mid P_j^{SS} \in P^{SS}, \text{Overlap}(P_i^{SS})\}$ の中から、推定確率 $\text{Pr}_{cls}(P^{SSi_overlap})$ が最も高い点群サブセット $\max(\text{Pr}_{cls}(P^{SSi_overlap}))$ を $P_k^{SSbest} (\in P^{SSbest} \subset P^{SS})$ として検出し、その点群サブセットの特徴形状クラス $L_c (\in P_k^{SSbest})$ を特定する。

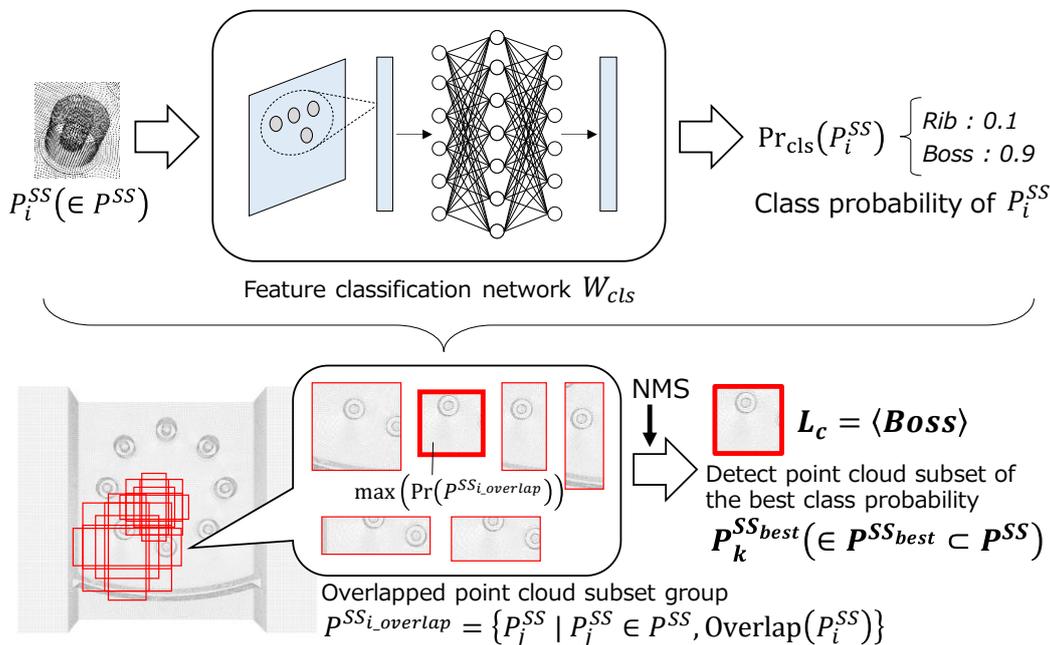


図 3-2-8 特徴形状領域の検出と特徴形状クラスの特定

図 3-2-9 に示すように、Non-Maximum Suppression (NMS) は、点群サブセットを囲む直方体領域であるバウンディングボックスの重なりを Intersection over Union (IoU) で評価し、閾値以上の場合に領域が重なっていると判断し、それらの点群サブセットの中から最も推定確率の高い点群サブセットを残し、他を削除するアルゴリズムである。

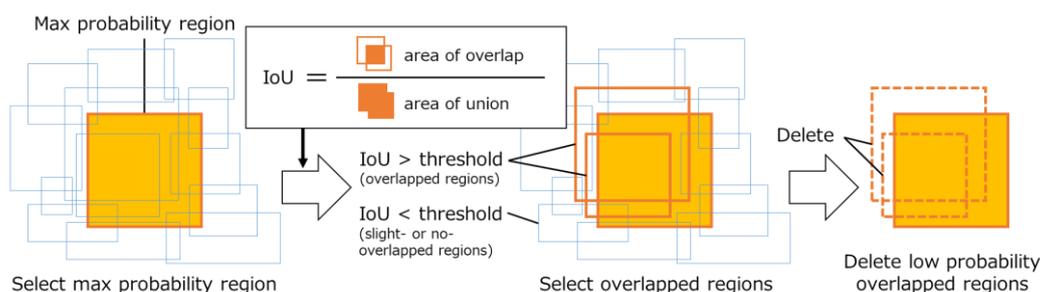


図 3-2-9 Non-Maximum Suppression (NMS) による最大推定確率領域の検出

3-2-7 STEP7 : 局所特徴領域のラベル割当て

最後に、図 3-2-10 で示すように、STEP6 で特徴形状クラスを特定した点群サブセット $P_k^{SS_{best}} (\in P^{SS_{best}})$ を局所特徴領域セグメンテーションネットワーク W_{seg} に入力し、各点群サブセット $P_k^{SS_{best}} (\in P^{SS_{best}})$ 内の各ポイント $p_{k,n}^{SS_{best}} (\in P_k^{SS_{best}})$ における局所特徴領域の推定確率 $Pr_{seg}(p_{k,n}^{SS_{best}})$ を算出する。そして、入

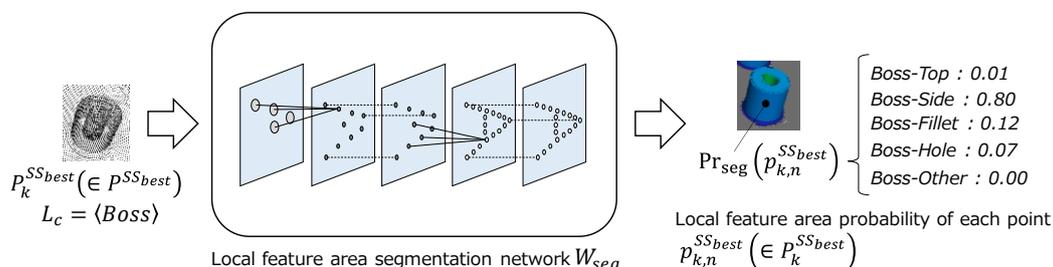


図 3-2-10 点群サブセットにおける各ポイントの局所特徴領域推定確率の算出

入力点群 $P^{IN} = \{p_i^{IN}\}$ の各ポイント p_i^{IN} の局所特徴領域を、対応する複数の点群サブセット $P_k^{SS_{best}} = \{p_{k,n}^{SS_{best}}\}$ のポイント $p_{k,n}^{SS_{best}}$ における推定確率 $\text{Pr}_{\text{seg}}(p_{k,n}^{SS_{best}})$ から特定し、入力点群 $P^{IN} = \{p_i^{IN}\}$ の各ポイント p_i^{IN} に局所特徴領域のラベル（図 3-2-1）を割当てた出力点群 $P^{OUT} = \langle V, L_c, L_a \rangle$ を得る。ただし、STEP6 の NMS において、点群サブセット $P_k^{SS_{best}} (\in P^{SS_{best}})$ 間で僅かな重なり合いを許容しているため、点群サブセット間に複数の重複ポイントが存在し、ラベル割当てに競合が生じる。この場合、図 3-2-11 にあるように、競合ポイントの中で最も高い推定確率の局所特徴領域にラベルを特定する。

ここで得られたラベル付き出力点群を用いて、入力 CAD モデルの各面分のラベルを特定する。そして、商用 CAE プリソフトウェアのマクロ機能を用いて、特定された面分ごとのラベルを参照し、仕様に適合した FE メッシュを自動生成することが可能になる。

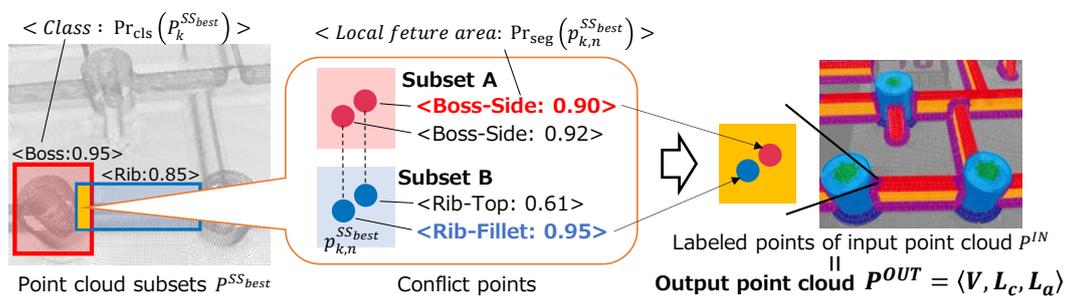


図 3-2-11 競合ポイントのラベル割当て

3-3 検証実験

ここでは、開発した特徴形状認識アルゴリズムの有効性を以下の検証実験によって確認する。

検証実験内容

- ① 単体の特徴形状の認識実験（3-3-1 節）
- ② 互いに独立して配置された特徴形状の認識実験（3-3-2 節）
- ③ 滑らかに接続された特徴形状の認識実験（3-3-3 節）
- ④ 学習ネットワーク及びデータセットの違いによる比較検証(3-3-4 節)
- ⑤ 手法 1 の検証モデルによる認識実験（3-3-5 節）

3-3-1 検証実験①：単体の特徴形状の認識実験

この検証では、本手法における特徴形状クラス分類ネットワーク W_{cls} 及び局所特徴領域セグメンテーションネットワーク W_{seg} の認識性能を確認することを目的とし、単体のリブとボスを用いた認識性能確認実験を行う。

特徴形状クラス分類ネットワーク W_{cls} 及び局所特徴領域セグメンテーションネットワーク W_{seg} のトレーニング及び検証実験に使用した特徴形状 CAD モデルデータセット D^S の形状バリエーションを図 3-3-1 に示す。まず、パラメトリック CAD により形状パラメータデータセット D^P から 4188 の特徴形状 CAD モデルを生成し、次に、生成した特徴形状 CAD モデルを構成する各面分に対し、図 3-3-2 に示す特徴形状クラス毎の局所特徴領域ラベルを設定することで、特徴形状 CAD モデルデータセット D^S を生成し、最終的に、それらを点群に変換することで特徴形状点群トレーニングデータセット D^P を作成した。4188 モデルの内、3385 モデルを 10 クロスバリデーションによるトレーニングに使用し、残りの 803 モデルをテストモデルとした。

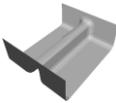
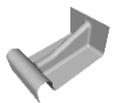
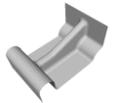
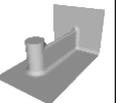
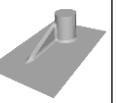
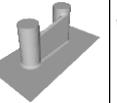
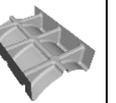
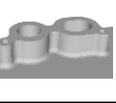
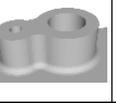
	Simple feature			Complicated feature				
RIB CLASS								
BOSS CLASS								

図 3-3-1 検証用の特徴形状 CAD モデルデータセットの形状バリエーション（異なるトレーニングデータセットの比較検証（検証実験④）において，“Simple feature”のみを使用した検証を行うが，それ以外の検証では，全形状バリエーションを使用する）

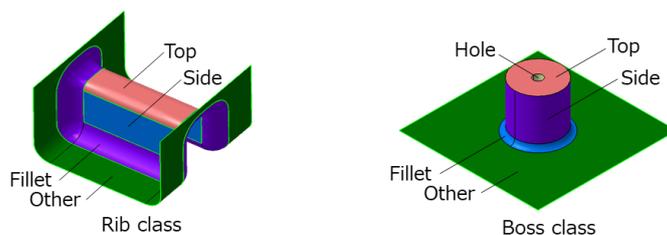


図 3-3-2 入力 CAD モデルの特徴形状クラス及び局所特徴領域ラベル

図 3-3-3 に単体のリブとボスの認識結果の一部を示す．特徴形状クラス毎に評価した mean Intersection over Union (mIoU) は，リブクラス:0.988, ボスクラス 0.997 であり，全体の mIoU は，0.992 であった．この結果は，特徴形状クラス分類ネットワーク W_{cls} 及び局所特徴領域セグメンテーションネットワーク W_{seg} を用いた本手法が，単体として存在する滑らかな曲面で構成された特徴形状の認識に対し，十分な認識精度を確保できることを示している．ここで，特徴形状クラス毎の mIoU は，その特徴形状クラスにおける局所特徴領域毎の IoU の平均値であり，全体の mIoU は，特徴形状クラス毎の mIoU の平均値である．

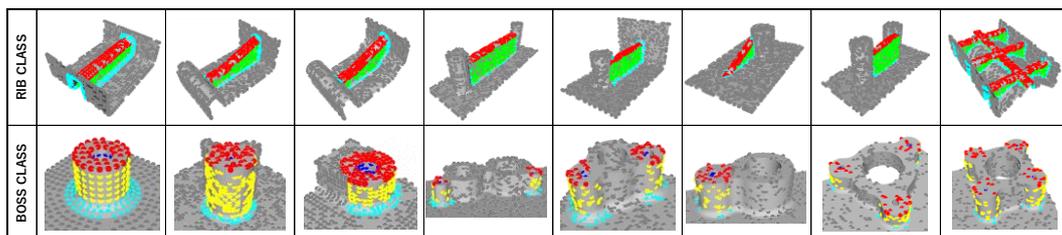


図 3-3-3 検証実験①：単体のリブとボスの認識結果

(mIoU：リブ:0.988, ボス:0.997, 全体:0.992)

3-3-2 検証実験②：互いに独立して配置された特徴形状の認識実験

複雑な入力 CAD モデルを用いて検証を行うにあたり，検証実験①に対して増強したトレーニングデータセットを作成し，特徴形状クラス分類ネットワーク W_{cls} 及び局所特徴領域セグメンテーションネットワーク W_{seg} のトレーニングを実施した．まず，各形状パラメータの設定値をパラメトリック CAD により数多く振ることで 22380 モデルを生成した．さらに，点群への変換において，点密度を検証実験①に対して 3 倍にした．作成した特徴形状点群トレーニングデータセット D^P の 22380 モデルの内，17904 モデルを 10 クロスバリデーションによるトレーニングに使用し，残りの 4476 モデルをテストモデルに使用した．その結果，mIoU は 0.970 となり，2 つのネットワークを用いた単体の特徴形状認識において，十分な認識精度が得られた．ここで構築した特徴形状クラス分類ネットワーク W_{cls} 及び局所特徴領域セグメンテーションネットワーク W_{seg} は，そのまま検証実験②③④で使用する．

検証実験②では，入力 CAD モデル S^{IN} 上に複数のリブとボスが互いに独立して配置されている場合に，提案したアルゴリズムが正常に動作することを確認する．そのため，図 3-3-4 に示す 8 つのボスと 1 つのリブを同一平板上に独立して配置した検証用入力 CAD モデル（モデル A）を作成した．同一平板上に配置したことで，Multi-Scale Bounding Box (MSBB) による特徴形状候補領域の抽出 (STEP5) を 2 次元的に扱うことが可能になり，MSBB の

高さ方向を無視できる。したがって、本検証においては、二次元画像を取り扱う SSD の場合と同様に、MSBB の数を 8732 個とし、特徴形状候補領域点群サブセット P_l^{SS} ($\in P^{SS}$) の抽出処理を簡易化した。

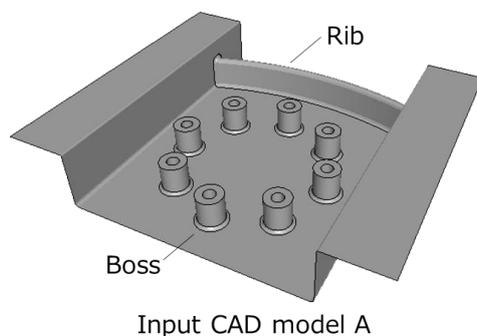


図 3-3-4 検証実験②：検証用入力 CAD モデル（モデル A）

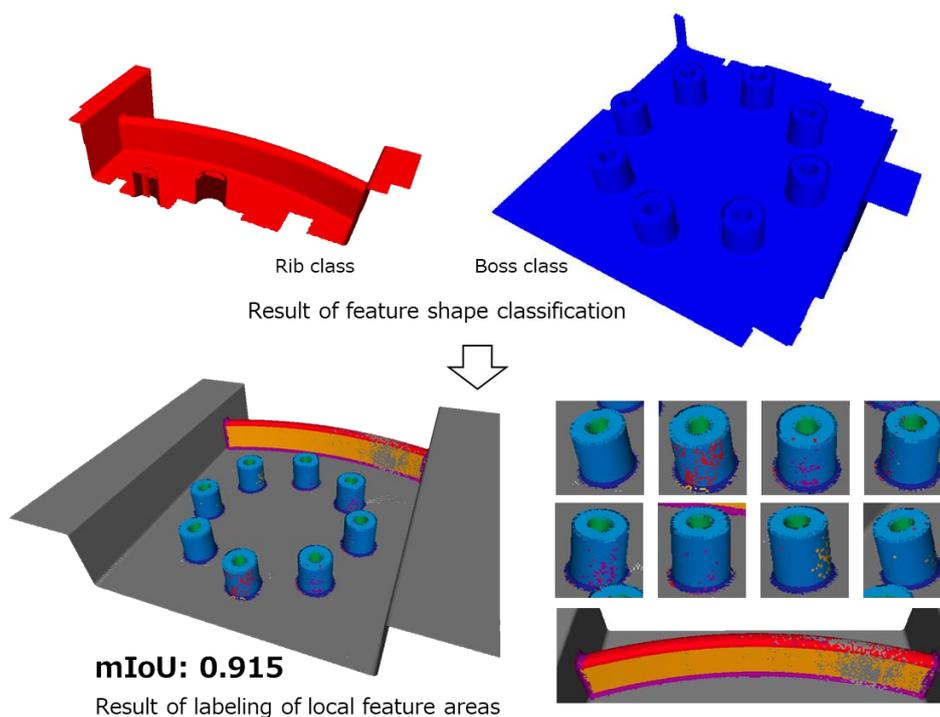


図 3-3-5 検証実験②：モデル A の認識結果（上図：特徴形状クラス分類結果（Red: Rib class, Blue: Boss class），下図左：局所特徴領域認識結果，下図右：局所特徴形状結果の詳細（Light blue: Boss-Top, Blue: Boss-Side, Dark blue: Boss-Fillet, Green: Boss-Hole, Red: Rib-Top, Orange: Rib-Side, Purple: Rib-Fillet, Gray: Other））

検証結果を図 3-3-5 に示す。全ての特徴形状が検出され、局所特徴領域が十分な精度でラベル付けされており、mIoU は 0.915 であった。この結果から、独立して配置された複数の特徴形状の認識において、深層学習ネットワークを用いた本アプローチが有効であることが確認できた。

3-3-3 検証実験③：滑らかに接続された特徴形状の認識実験

この検証では、鋳造部品や樹脂部品に近い比較的複雑な形状を入力モデルとし、滑らかに接続された複数の特徴形状の認識に対する正常動作を確認する。

深層学習ネットワークには、検証実験②でトレーニングした特徴形状クラス分類ネットワーク W_{cls} 及び局所特徴領域セグメンテーションネットワーク W_{seg} を用いる。また、検証モデルとして、図 3-3-6 に示す 2 つのモデル（モデル B, C）と、図 3-3-7 に示すモデル B を変形した 2 つのモデル（モデル D, E）を作成した。特に後者は、より滑らかで複雑な曲面形状における動作確認を目的としている。また、これらのモデルを、検証実験②と同様に 2 次元的に扱うことで、MSBB の数を 8732 個とし、特徴形状候補領域点群サブセット $P_l^{SS}(\in P^{SS})$ の抽出処理を簡易化した。

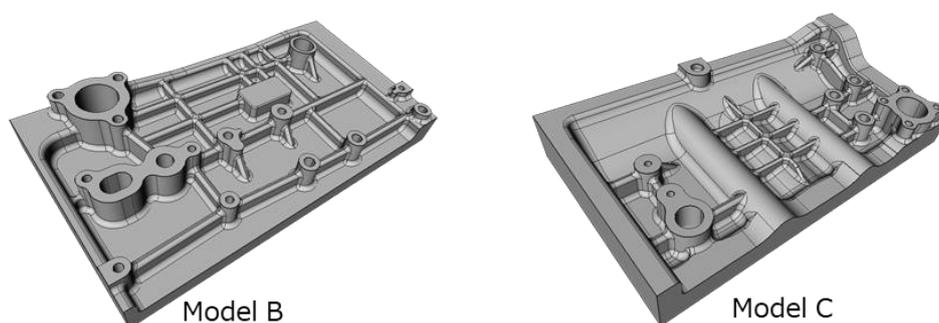


図 3-3-6 検証実験③：検証用入力 CAD モデル（モデル B, C）

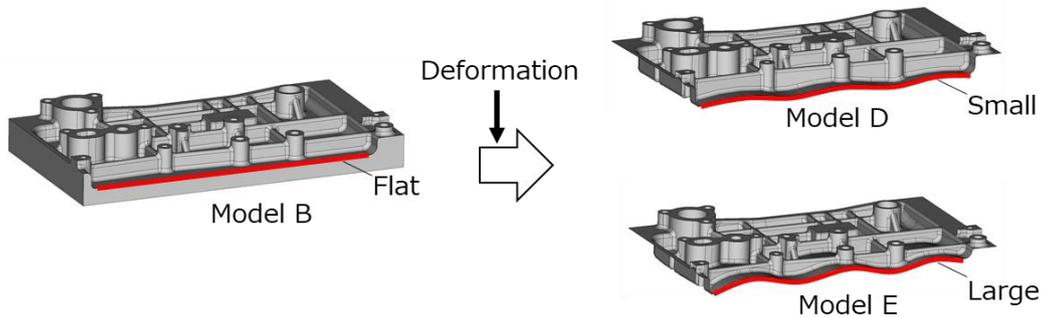


図 3-3-7 検証実験③：検証用入力 CAD モデル（モデル D, E）

モデル B と C による認識結果を図 3-3-8, 図 3-3-9 に示す。mIoU は、それぞれ 0.626 と 0.588 であり、ラベルは、各特徴形状が目視により識別できる程度に割付けられている。この結果から、滑らかに接続された特徴形状においても、深層学習ネットワークを用いた本アプローチが正常に動作することが確認できた。しかし、検証実験②のモデル A の場合と比較して、mIoU による認識精度が劣る結果となった。原因は、図 3-3-10 に示すように、特徴形状境界の認識精度の低下である。MSBB の領域バリエーション、及び NMS で選定された点群サブセット間の境界における競合回避方法に課題がある可能性がある。これらの認識精度改善は、今後の課題である。

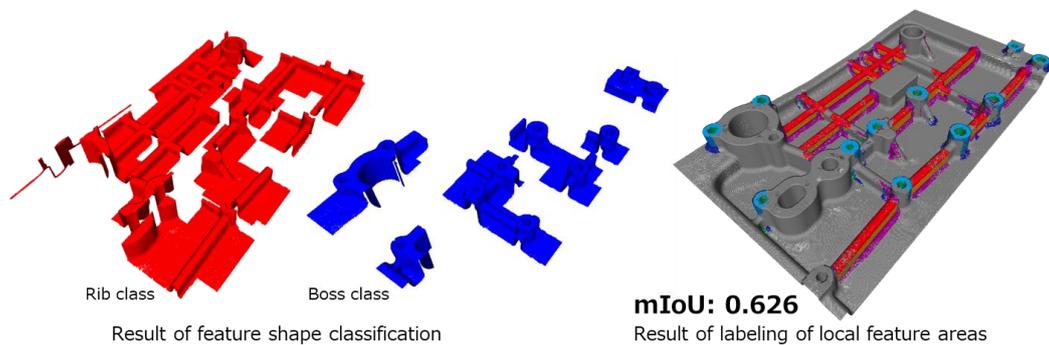


図 3-3-8 検証実験③：モデル B の認識結果

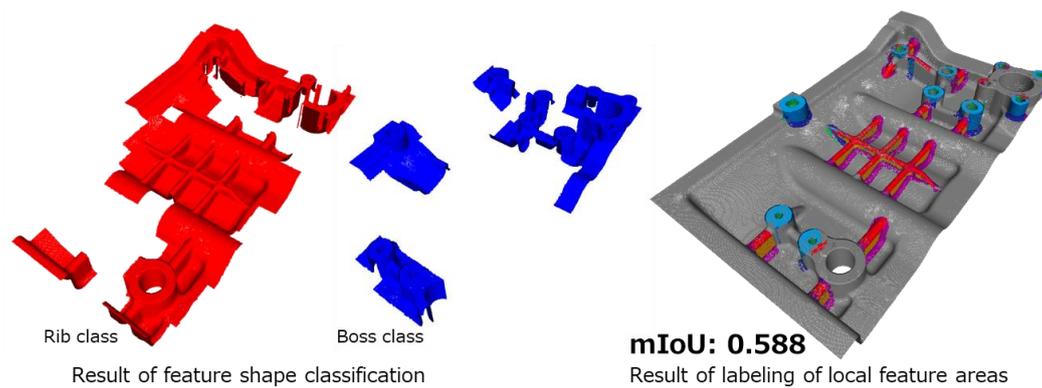


図 3-3-9 検証実験③：モデル C の認識結果

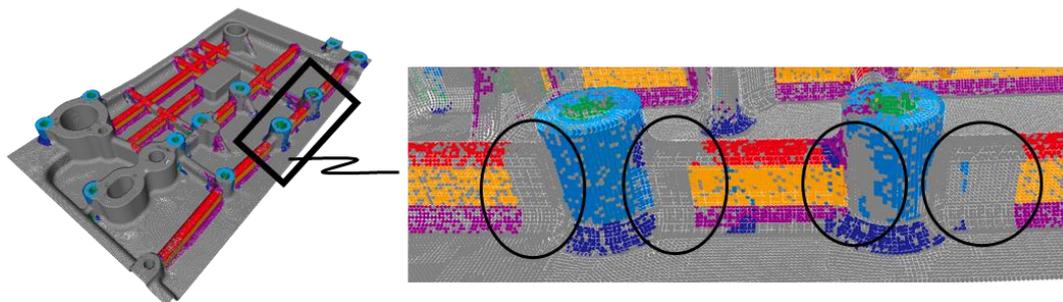


図 3-3-10 検証実験③：モデル B の認識結果（認識精度の劣化部）

モデル D と E による認識結果を図 3-3-11 に示す。mIoU は、それぞれ 0.508 と 0.527 であり、ラベルは、各特徴形状が目視により識別できる程度に割付けられている。この結果から、より複雑且つ滑らかに接続された特徴形状においても、深層学習ネットワークを用いた本アプローチが正常に動作することが確認できた。しかし、モデル B 及び C と同様に、検証実験②のモデル A に対して mIoU による認識精度が低下しており、また、特徴形状境界付近において特に認識精度が低下する結果となった。

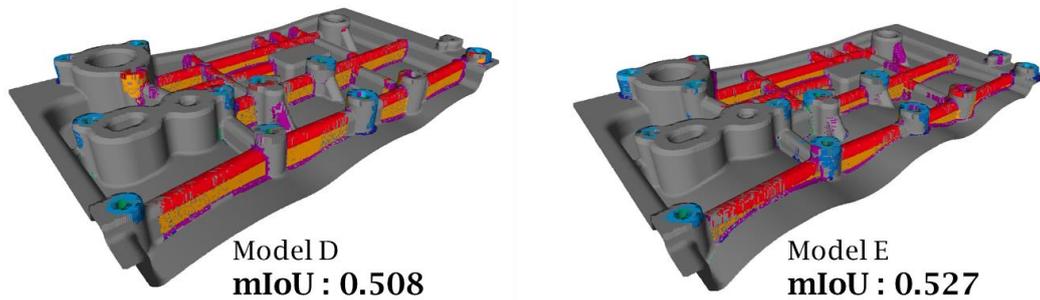


図 3-3-11 検証実験③：モデル D と E の認識結果

ここまで示したように、特徴形状認識パイプラインでは、各ポイントにラベル情報を割当てて、その後、FEメッシュ自動生成パイプラインにおいて、各ポイントをCADモデルの各面分に投影し、そのラベル情報を各面分に投票することで、各面分のラベルを決定していく。そして、面分ごとのラベル情報を参照することで、仕様に適合したFEメッシュを自動生成していくことが可能になる。このとき、CADモデル上の特徴形状境界は、面分境界によって保障されているため、出力点群の各ポイントの認識精度がある程度信頼できる場合、出力点群によって特徴形状境界を正確に検出できなくとも、CADモデル上の特徴形状面分に対して正しくラベル付けすることは可能である。

3-3-4 検証実験④：学習ネットワーク及びデータセットの違いによる比較検証

一般的な深層学習ネットワークを用いた物体認識の認識性能は、トレーニングデータセットとネットワーク構造によって影響を受ける。トレーニングデータセットは、バリエーション及び量が多く質が高いものが必要であり、また、ネットワーク構造は対象となる問題に対して最適なものを選定する必要がある。三次元点群深層学習ネットワークの場合は、さらに、トレーニングデータセットに使用する特徴形状点群の形状の複雑さとポイントのサンプリング密度によって影響を受ける可能性がある。これは、三次元点群による

離散的形状表現の場合，ポイントのサンプリング密度によって，再現できる形状の詳細さが変わるためである．つまり，複雑な形状を再現するには，サンプリング密度を高くしなければならない．

これらを考慮し，形状の複雑さとバリエーション数，及びポイントのサンプリング密度の違いにより，4つの特徴形状点群トレーニングデータセットを作成し，認識性能比較を行った．また，深層学習ネットワークの違いを比較するため，PointNet[Qi17-1]を用いて深層学習ネットワークを構築し，本手法で採用している PointNet++[Qi17-2]との認識性能比較を行った．

実施した比較検証の一覧を表 3-3-1 に示す．(1)は，検証実験②③の条件と結果であり，(2)~(5)は，(1)に対して，特徴形状点群のポイントサンプリング密度，形状の複雑さ及びバリエーション数，深層学習ネットワークを変更したものである．ここで，表 3-3-1 内の「Point sampling densities」は，特徴形状点群の平均点間距離によるサンプリングの粗密を示しており，「Dense」は密（1mm），「Sparse」は粗（3mm）としている．また，「Feature shape complexities」は，トレーニングデータセットに含まれる特徴形状の複雑さとバリエーション数を示しており，「Simple」は図 3-3-1 の「Simple feature」で示す 6 種類の単純形状のみを含み，「Complicated」は，図 3-3-1 の「Complicated feature」で示す 10 種類の複雑形状を含む全 16 種類の形状バリエーションを含む．これらの組合せにより 4 つのデータセットを作成し，(1)と(5)は密&複雑，(2)は密&単純，(3)は粗&複雑，(4)は粗&単純とした．また，深層学習ネットワーク（Deep neural network）は，トレーニングした深層学習ネットワーク構造の種類を示しており，(1)~(4)は PointNet++，(5)は PointNet とした．最後に，これらの比較検証で使用する入力 CAD モデルは，図 3-3-12 に示すように，検証実験②③で使用したモデル A，B，C とした．

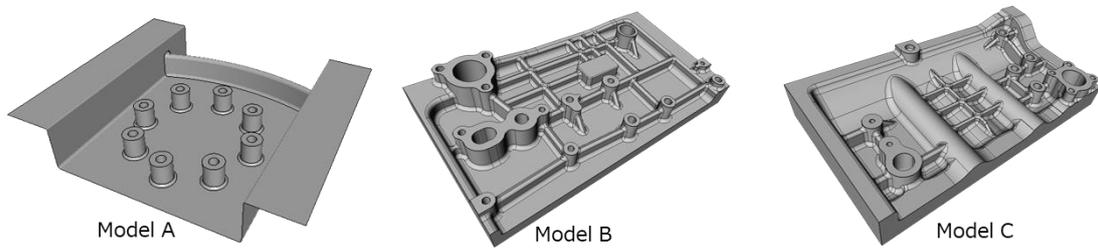


図 3-3-12 検証実験④：検証モデル（モデル A, B, C）

表 3-3-1 検証実験④：比較検証結果

Setting		(1)	(2)	(3)	(4)	(5)
Training conditions	Point sampling densities	Dense	Dense	Sparse	Sparse	Dense
	Feature shape complexities	Complicated	Simple	Complicated	Simple	Complicated
	Deep neural network	Point Net++	Point Net++	Point Net++	Point Net++	Point Net
mIoU results	Model A	0.915	0.831	0.887	0.660	0.564
	Model B	0.626	0.400	0.560	0.386	0.477
	Model C	0.588	0.527	0.585	0.472	0.507

トレーニングデータセットの影響を調査した(1)~(4)の比較結果から、検証実験②③で使用した(1)が最も認識精度が高く、形状が複雑でバリエーションが多い(1)と(3)の認識精度が高い傾向であることがわかった。

形状の複雑さを同じとしてサンプリング密度の違いで mIoU を比較すると、同じ「Complicated」でサンプリング密度が低下する(1)→(3)で、モデ

ル A : -0.028, モデル B : -0.066, モデル C : -0.003, 同様に

「Simple」の(2)→(4)で, モデル A : -0.171, モデル B : -0.014, モデル C : -0.055 となった. また, ポイントのサンプリング密度を同じとして形状の複雑さの違いで mIoU を比較すると, 同じ「Dense」で形状の複雑さが低下する(1)→(2)で, モデル A : -0.084, モデル B : -0.226, モデル C : -0.061, 同様に「Sparse」の(3)→(4)で, モデル A : -0.227, モデル B : -0.174, モデル C : -0.113 であった.

この結果は, トレーニングデータセットの特徴形状点群における形状の複雑さ及びバリエーション数が認識精度に大きく影響しており, また, それらが十分でない場合に, 特徴形状点群のポイントのサンプリング密度の影響が大きく出ること示している. 特に, モデル A において, 形状の複雑さ及びバリエーションが低下した場合に, ポイントのサンプリング密度の低下による認識精度への影響が大きいことがわかる. モデル A は, 比較的単純な形の特徴形状から構成されており, また, それぞれの特徴形状が互いに独立して配置されており, さらに, 「Simple」及び「Complicated」の両方に単純形状が含まれていることから, 形状の複雑さ及びバリエーション数の影響は少なく, しかし, 「Simple」且つ「Sparse」では点群での形状再現性が十分ではなく, 認識精度に影響が出たと考えられる. これらの結果から, トレーニングデータセットの特徴形状点群は, ポイントのサンプリング密度が高く, また, 形状バリエーションの幅が広く, さらにその量が多い方が, より高い認識精度が得られることがわかった. また, (1)~(4)の中で, 検証実験②③の結果である(1)が最も高い認識精度を示していることから, 検証実験②③の深層学習ネットワークトレーニングが妥当であると言える.

次に, 深層学習ネットワーク構造の違いを, 同じトレーニングデータセットを用いた(1)と(5)で比較する. 表 3-3-1 の結果から, PointNet++からPointNet への置き換え(1)→(5)で, モデル A : -0.351, モデル B : -0.149, モデル C : -0.081 であり, PointNet++の方が大幅に優れていることがわかる. これは, PointNet++が, PointNet で課題となっていた局所形状の認識を, 階層構造ネットワークにすることで改善したものであり, そのため, 入

力 CAD モデル上の複数の特徴形状を認識することを目的とした本手法に適していたためである。したがって、本手法において、深層学習ネットワークに PointNet++ を選択したことは、妥当であると言える。

3-3-5 検証実験⑤：手法 1 の検証モデルによる認識実験

ここでは、検証モデルのバリエーションを増やし、さらなる課題を抽出する目的で、手法 1 の検証モデルを用いた追加検証を実施した。ただし、モデル F の特徴形状クラス分類ネットワーク W_{cls} 及び局所特徴領域セグメンテーションネットワーク W_{seg} には、検証実験②③と同様のものを用いており、モデル G には、図 3-3-13 に示すように、特徴形状のバリエーションを追加している。これは、モデル G に対して、検証実験①②及びモデル F と同様の深層学習ネットワークを適用した結果、全く認識できなかったことによるトレーニングデータセットのチューニングである。

認識結果を図 3-3-14 に示す。モデル F 及び G の両結果において、特徴形状を目視で識別可能な程度のラベル割付けに成功しているが、mIoU は、0.3~0.4 程度となり、検証実験①②と比較して大幅に認識精度が低い。

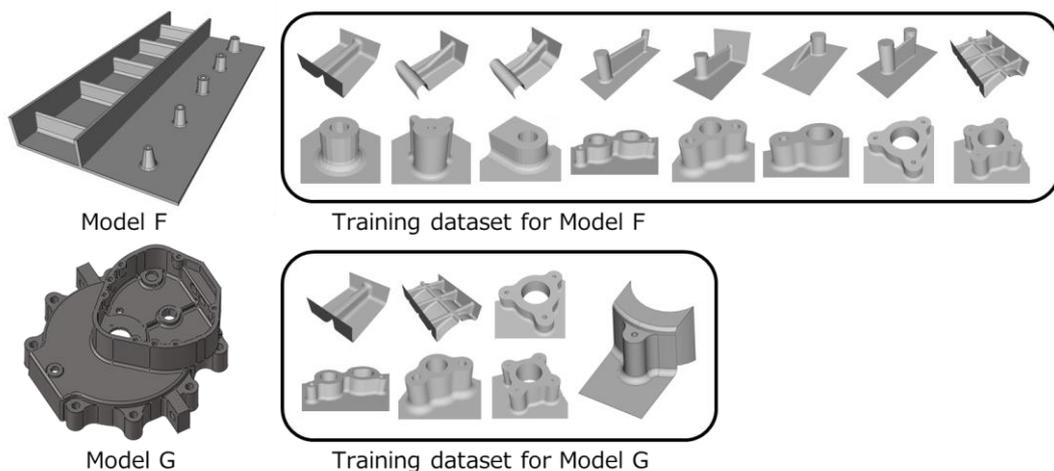


図 3-3-13 検証実験⑤：検証モデルとトレーニングデータ

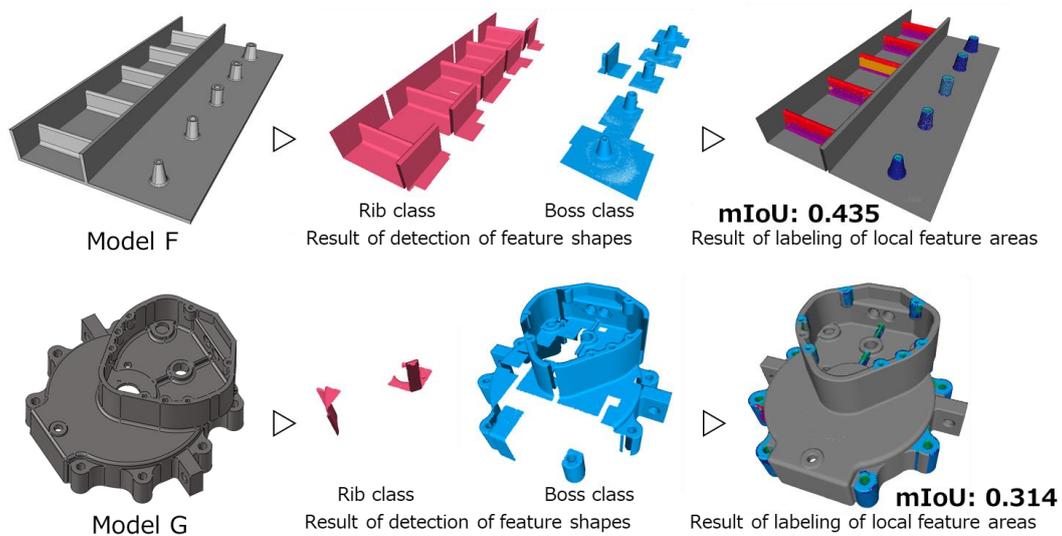


図 3-3-14 検証実験⑤：手法 1 の検証モデルによる認識結果

モデル F で認識精度が低い原因は，図 3-3-15 に示すように，トレーニングデータセットの特徴形状が，入力形状に対して最適ではなかったことに起因する．トレーニングデータセットの全ての特徴形状が，側面—フィレット—ベース面の関係において，側面とベース面が直角になっていた．その結果，ベース面に対して直角な面のみを側面とし，直角以外の面であればフィレットとして認識したと考えられる．

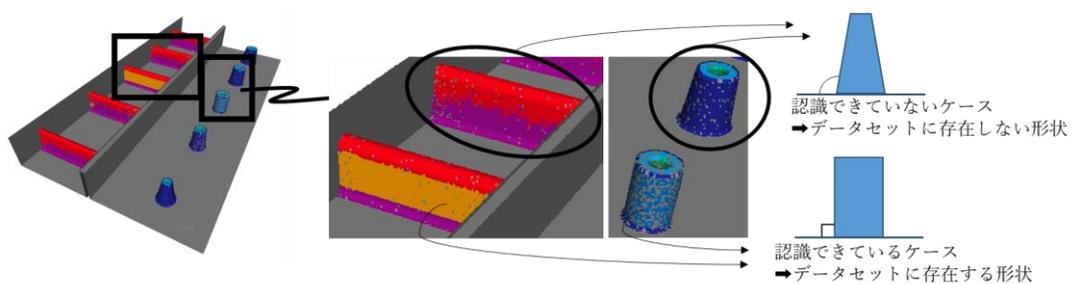


図 3-3-15 検証実験⑤：手法 1 の検証モデルによる認識結果（認識精度の劣化部）

先述した通り，モデル G は，モデル F と同様のトレーニングデータセットを使用した場合，全く認識できなかった．そのため，対象とする入力 CAD モデルの特徴形状に合わせてトレーニングデータセットを変更した．その結果，認識精度は低いものの認識が可能になった．モデル G のトレーニングデータセットには，形状側面に付くボス形状を残し，入力 CAD モデルに含まれる特徴形状に近いボス形状を追加し，さらに，単純なリブ形状とリブ形状同士が接続したリブ形状のみを残した．この結果，リブ形状は検出されなかったものの，手法 1 で 1 つの参照特徴形状からは認識できていなかった上段にある小さなボス形状を含むほぼ全てのボス形状を検出できた．

一方，表 3-3-2 に示すように，モデル G における処理時間は，特にトレーニング時間（STEP1～4）が非常に大きく，また，同モデルにおける手法 1 の処理時間と比較しても，本手法のボトルネックであることがわかる．

これらの検討結果から，参照特徴形状の追加により検出可能な形状範囲の拡大が可能である手法 1 に対し，手法 2 では，トレーニングデータセットの調整により認識精度を高めることが可能であることがわかる．また，最適なトレーニングデータセットを構築するためのトライ&エラーにおいてトレーニング時間が問題になることがわかった．これは，効率よく認識精度を高めるための最適なトレーニングデータセットを構築する統一的な方法が必要であることを示している．この課題は，本研究における今後の課題であり，深層学習アプローチにおける共通の課題でもある．

表 3-3-2 モデル G の処理時間

トレーニング (STEP1～4)	ラベル割付け (STEP5～7)	合計
3773 分	5 分	3778 分
(実行環境) CPU : Intel Core i9-10900K @3.7Hz x 20Core, CPU Memory : 128GB, GPU : NVIDIA GEFORCE RTX 2080 Ti, GPU Memory : 11GB GDDR6, OS : Ubuntu 18.04 64bit		

3-4 まとめと今後の課題

本研究では，製品形状 CAD モデルを入力とし，特徴形状毎に規定された仕様に適合した FE メッシュを作成手順逐次実行方式により自動生成することを前提とした三次元点群と深層学習を用いた三次元特徴形状認識技術を開発し，その有効性を示すことができた。

本章で開発した技術の成果を以下にまとめる。

(1) PointNet++に基づく分類とセグメンテーションの2つの深層学習ネットワークを用いた自由曲面特徴形状認識手法の実現

三次元点群を直接取り扱う PointNet++に基づき，特徴形状クラス分類ネットワーク及び局所特徴領域セグメンテーションネットワークの2つの深層学習ネットワークを構築し，特徴形状クラスとその局所特徴領域を認識する特徴形状認識手法を開発した。これにより，認識可能な特徴形状のバリエーションを拡大する際，トレーニングデータセットに新たな特徴形状を追加し，深層学習ネットワークを再トレーニングすることで，特徴形状バリエーションの違いに依存せず統一的且つ拡張性の高いアルゴリズムによる特徴形状認識を実現した。また，離散的形状表現である三次元点群を用いることで，PDQ 劣化部を含む CAD モデルに対する頑健動作を実現した。

(2) Multi-Scale Bounding Box と Non-Maximum Suppression を組合せた特徴形状領域検出手法の開発

Single-Shot multi-box Detector (SSD) におけるデフォルトボックスをバウンディングボックスとして生成した Multi-Scale Bounding Box (MSBB) を用いて，入力点群の中から特徴形状が存在する可能性のある部位を抽出し，深層学習ネットワークにより得られた点群サブ

セット毎の推定確率を用いた Non-Maximum Suppression (NMS) により、重複する複数の点群サブセットの中から、最も推定確率の高い特徴形状クラスとして、1つの点群サブセットを抽出する特徴形状領域検出手法を開発した。これにより、パラメトリック CAD で大量生成可能な単体特徴形状による深層学習アプローチを実現し、また、複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状 CAD モデルに対しての頑健動作を実現した。さらに、深層学習ネットワークの認識精度のみに依存せず、段階的に認識精度を向上させる手法を実現した。

(3) パラメトリック CAD による効率的なトレーニングデータセット生成から、深層学習による特徴形状認識までの一連の処理プロセスの実装

深層学習ネットワークのトレーニングにあたっては、形状パラメータを入力データとし、パラメトリック CAD で効率的に生成した CAD モデルデータセットを基に三次元点群トレーニングデータセットを生成する効率的なプロセスを開発し、また、認識にあたっては、入力 CAD モデルから MSBB により特徴形状が存在する可能性のある点群サブセットを生成し、深層学習ネットワークによる推定確率に基づき、NMS によって重複点群サブセットの中から特徴形状領域を特定し、さらに局所特徴領域を特定したうえで、入力点群の各ポイントにラベルを割当てるという段階的に認識精度を高めるプロセスを開発した。これらの一連のプロセスにより、PDQ 劣化部を含む CAD モデルや、複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状 CAD モデルに対して頑健に動作し、さらに、特徴形状タイプの違いに依存せず統一的で拡張性の高いアルゴリズムで動作する三次元特徴形状認識技術を実現した。

5 つの検証実験、①単体の特徴形状の認識実験、②互いに独立して配置された特徴形状の認識実験、③滑らかに接続された特徴形状の認識実験、④学

習ネットワーク及びデータセットの違いによる比較検証，⑤手法 1 の検証モデルによる認識実験により，本手法の有効性が確認された．これらにより，PointNet++に基づく特徴形状クラス分類ネットワーク及び局所特徴領域セグメンテーションネットワークの 2 つの深層学習ネットワークを用いた特徴形状認識が可能であることが示され，また，複数の特徴形状を持つ入力形状の中から，互いに独立して配置された特徴形状及び滑らかに接続された特徴形状の認識が可能であることが示された．さらに，PointNet++が本手法に最適であることや，トレーニングデータセットのチューニングにより認識精度を向上させることが可能であることが示され，また，手法 1 に対して広範囲の特徴形状認識が可能であることも示された．

今後の課題は以下 3 点であり，これらを解決することで，CAE モデル自動生成システムの実現が可能になるものと思われる．

(1) 特徴形状境界付近における認識精度の改善

特徴形状境界における認識精度の低下が顕著であり，これは，MSBB の領域バリエーション，及び NMS で選定された点群サブセット境界におけるラベル競合の回避方法に課題がある可能性がある．

(2) 最適なトレーニングデータセットの効率的な構築方法の開発

入力形状に最適なトレーニングデータセットを使用しなければ，認識精度が大きく低下し，処理時間が増大することが示された．認識精度に影響を与える要素として，特徴形状バリエーションの数及び形状の複雑さ，特徴形状点群のポイントサンプリング密度があり，これらを基に，最適なトレーニングデータセットとなる条件を効率よく発見する方法を開発する．

(3) 出力点群のラベル情報を参照して入力 CAD モデルの各面分にラベルを割付ける処理アルゴリズムの開発

本研究により，入力 CAD モデルに対し，特徴形状及び局所特徴領域のラベルを割付けた三次元点群を出力できることが示された．しかし，作成手順逐次実行方式 FE メッシュ自動生成システムを実現するには，出力されたラベル付き点群を利用し，入力 CAD モデルの各面分にラベルを割付ける処理アルゴリズムの開発が必要である．

(4) 作成手順逐次実行方式 FE メッシュ自動生成システムの実用化に向けた詳細検証と開発

現時点では，様々なパターンを入力 CAD モデルに対する検証は行われておらず，また，それらに対する FE メッシュ自動生成マクロの開発もできていない．様々なパターンを入力 CAD モデルに対応し，規定された仕様に適合した FE メッシュを自動生成するため，今後これらを解決し，作成手順逐次実行方式 FE メッシュ自動生成システムを開発していく必要がある．

第4章

認識特徴形状に基づく FE メッシュ 自動生成と提案手法の有効性検証

4-1 手法1の特徴形状認識結果に基づく

マッピング方式 FE メッシュ自動生成

本節では, 手法1の類似形状認識技術が前提としているマッピング方式 FE メッシュ自動生成の実現性を確認するため, 手法1の検証実験②③④での認識結果に基づき, 参照特徴形状と関連付いた FE メッシュを, 発見した特徴形状にマッピングすることで FE メッシュを生成できることを確認する.

図 4-1-1 に検証実験②の認識結果に基づく FE メッシュマッピング結果を示す. 第2章で述べた検証実験②の認識結果は, 参照特徴形状と形状が異なり, また, 互いに形状が異なる4つのリブ形状と3つのボス形状の認識, 及び参照特徴形状と同一形状のリブ形状とボス形状それぞれ1つずつの認識に成功していた. したがって, 上記で唯一認識に失敗していた図 4-1-1 の図中右上のボス形状は, マッピングできていない. また, 参照特徴形状と同一形状の中央に配置されたリブ形状とボス形状のマッピングには成功しているが, その他の類似形状は, 図 4-1-1 に赤枠で示したように, ゆがみが生じている.

検証実験③④の認識結果に基づく FE メッシュマッピングの結果を図 4-1-2 の左図に示す. 先ほどと同様に, 参照特徴形状と近い形状ではマッピングに成功しているが, それ以外の形状では, 図 4-1-2 の左図赤枠で示したようにマッピング精度が高くない. その原因の1つとして, 射影変換行列が RANSAC に基づくアルゴリズムで算出されており, 精度にばらつきが出てい

ると考えられる。そのため、再度、RANSAC の反復回数を 10 倍に変更して認識処理を行い、得られた射影変換行列に基づき FE メッシュのマッピングを行った。結果は、図 4-1-2 の右図に示すように、入力 CAD モデル上の特徴形状の抽出は、8 つ中 5 つに成功しているが、マッピングについては、図 4-1-2 の右図赤枠で示すように、左図と同様の部位においても異なるマッピング結果になることが確認できた。



図 4-1-1 検証実験②の認識結果に基づく FE メッシュマッピング結果

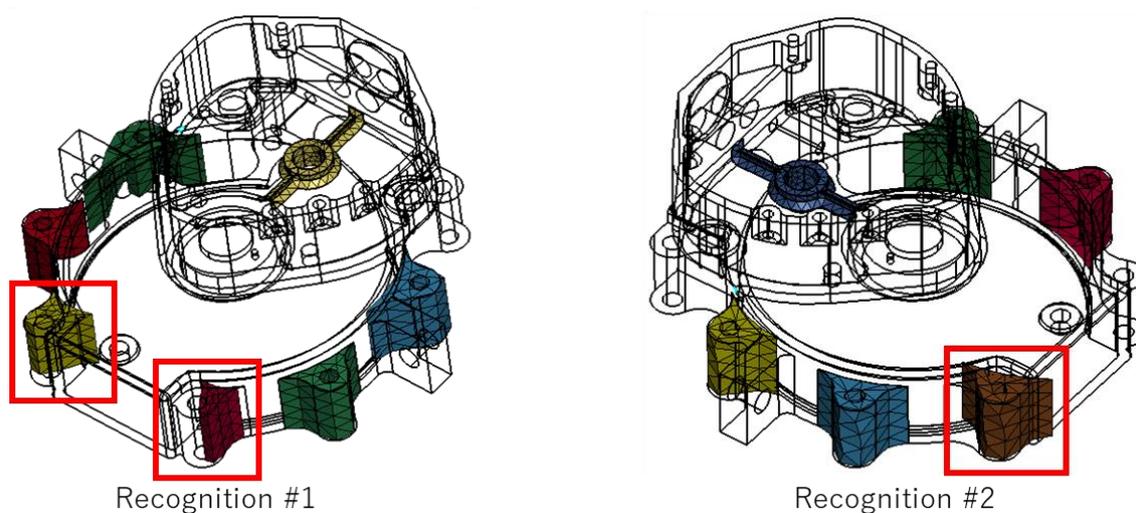


図 4-1-2 検証実験③の認識結果に基づく FE メッシュマッピング結果

参照特徴形状と発見形状との形状の乖離が大きい場合に起こるこれらのマッピング精度の問題は、射影変換行列の精度の問題であり、RANSACに起因するアルゴリズムの問題であると考えられる。精度向上にあたっては、射影変換行列計算の際、ランダムに選ぶ5ペアの類似キーポイントペアの選択方法に何らかの制約条件を設けることなどが有効と考えられる。しかしながら、手法1のコンセプトとして、抽出対象形状と類似する特徴形状を新たな参照特徴形状として再計算することが最も有効な方法と考える。

そこで、参照特徴形状バリエーションを増やして認識処理及びマッピングを行った結果を図4-1-3と図4-1-4に示す。ここで、参照特徴形状のバリエーション拡張に伴うマッピング精度向上を確認することを目的とし、マッピング部位とほぼ同じ形状となる入力CADモデル上の特徴形状部位を全て切り出し、位置を変更したものを参照特徴形状とすることで問題を簡単にした。その結果、図4-1-3と図4-1-4のように、全ての特徴形状部位に対して精度よくマッピングが行われることを確認できた。

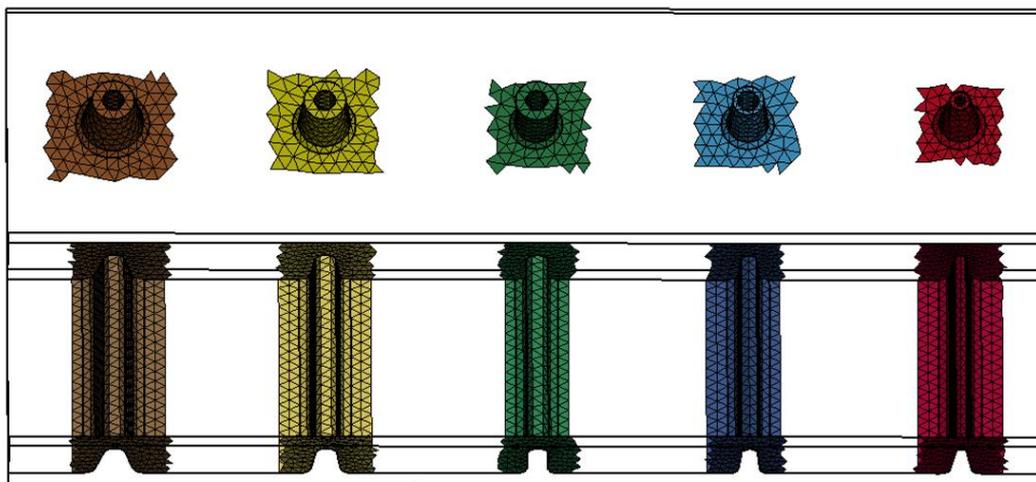


図 4-1-3 参照特徴形状バリエーションを拡張した場合の FE メッシュマッピング結果（検証実験②モデル）

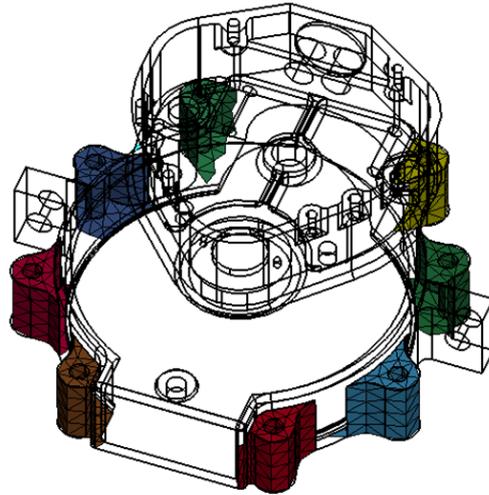


図 4-1-4 参照特徴形状バリエーションを拡張した場合の FE メッシュ
マッピング結果（検証実験③④モデル）

これらの結果から，手法 1 で参照特徴形状バリエーションを多く持つことにより，マッピング方式 FE メッシュ自動生成を実現可能であることが確認できた．一方で，1つの参照特徴形状から，形状が乖離する多くの類似特徴形状に対して効率よくマッピングができるよう射影変換行列の精度を高める必要があり，そのためのアルゴリズムの改善は，今後の課題である．

4-2 手法 2 によるの特徴形状認識結果に基づく

作成手順逐次実行方式 FE メッシュ自動生成

次に本節では、手法 2 の形状認識技術が目指している作成手順逐次実行方式 FE メッシュ自動生成の実現性を確認するため、手法 2 の検証実験の認識結果に基づき、商用 CAE プリソフトウェアのマクロ機能を用いることで、入力 CAD モデルの各面分にラベル付けを行い、面分のラベル情報に基づき FE メッシュを生成する。以下に示す一連の手順によりこれを行う。また、検証モデルには、図 3-3-12 にある第 3 章の検証実験②③で使用したモデル A, B, C を用いる。

手法 2 の特徴形状認識結果に基づく FE メッシュ生成手順

1. ラベル付けされた出力点群の各ポイントを入力 CAD モデルに投影
2. 各ポイントのラベル情報を、そのポイントが投影された面分に投票
3. 各面分で投票数が最多となるラベルを、その面分の特徴形状クラス及び局所特徴領域ラベルとして採用
4. 各面分のラベル情報を参照し、仕様に適合した FE メッシュを生成

手順 1~3 を実施した結果を図 4-2-1~図 4-2-3 に示す。これらの結果から、上記手順で CAD モデル上の各面分に対するラベル付けが可能であることがわかる。モデル A では、図 4-2-1 に示すように、全ての面分に対し、特徴形状クラス及び局所特徴領域のラベルが正しく割付けられた。これに対し、モデル B とモデル C では、図 4-2-2 と図 4-2-3 に示すように、多くの面分に対して異なるラベルが割付けられた。

これは、モデル A では、mIoU が 0.915 で認識精度が高く、モデル B 及び

Cでは、それぞれ 0.626, 0.588 で認識精度が高くないことによる。つまり、投票により各面分にラベルを割付ける手順が、点群の各ポイントにおける認識精度に依存するためである。一方で、図 4-2-2 の右上に示すように、必ずしも面分内の全ての領域で均質的にポイントの認識精度を確保できない場合や、点群上で特徴形状境界に曖昧さがある場合においても、面分のラベル割付けが可能であることがわかる。

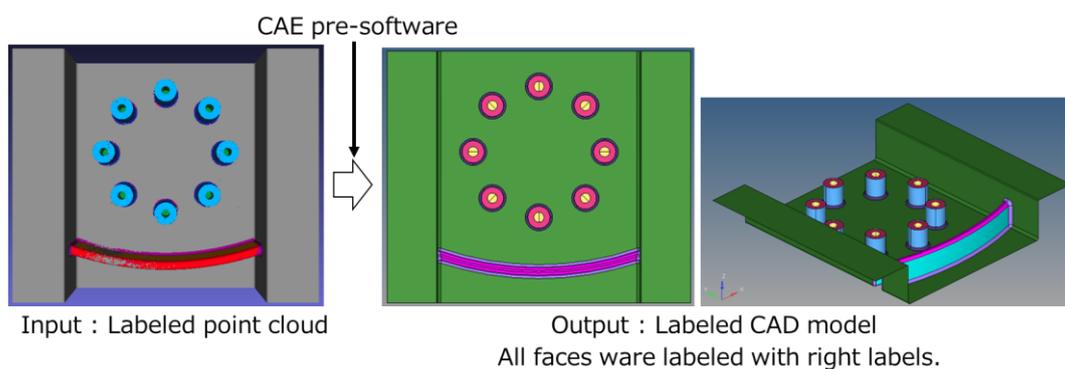


図 4-2-1 CAD モデルへのラベル割付け結果 (モデル A)

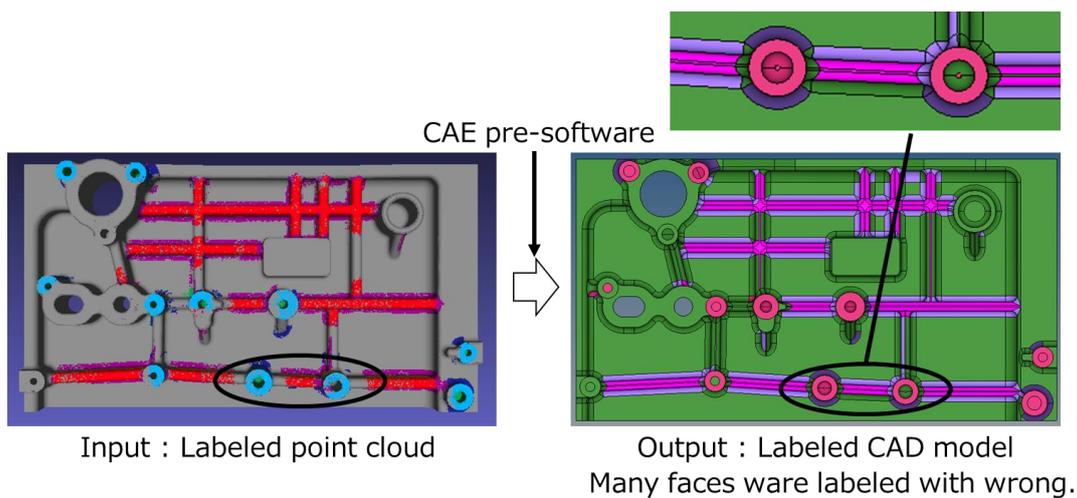


図 4-2-2 CAD モデルへのラベル割付け結果 (モデル B)

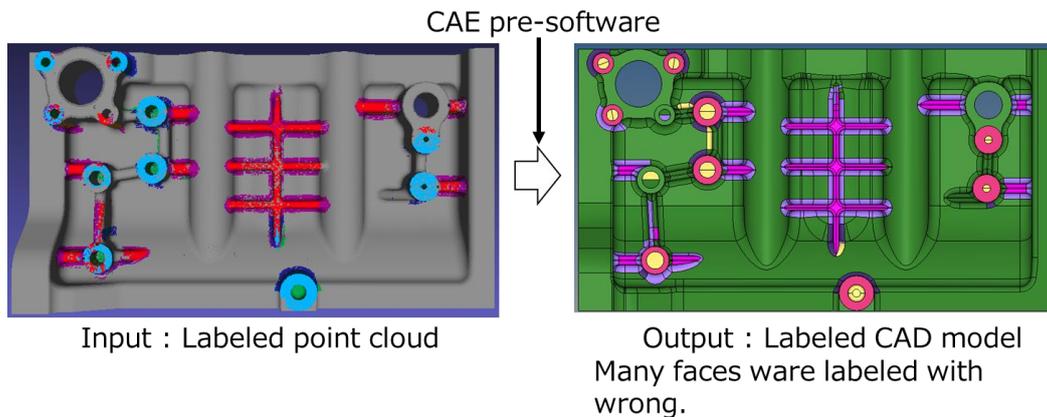


図 4-2-3 CAD モデルへのラベル割付け結果（モデル C）

次に、モデル A に対して手順 4 を実施した結果を図 4-2-4（上）に示す。ここで、検証用 FE メッシュ仕様として、ボス形状の穴に対して周方向に等 6 分割、リブ形状の上部円弧形状に対して等サイズ分割を規定した。結果、CAD モデル上の面分ラベル情報を用いて、商用 CAE プリソフトウェアのマクロ機能により、仕様に適合した FE メッシュを自動生成することができた。なお、モデル B と C については、CAD モデル上の各面分のラベルが正確に割付けられていないため、マクロ実行時にエラーとなり、FE メッシュは生成されなかった。

比較のため、商用 CAE プリソフトウェアの標準機能のみで FE メッシュを生成した結果を図 4-2-4（下）に示す。この結果から、商用 CAE プリソフトウェアの標準機能のみにより、仕様適合した FE メッシュを生成することはできず、人手を介す必要があることがわかる。

仕様適合した FE メッシュを生成するために、ここで用いた商用 CAE プリソフトウェアのマクロ機能による具体的な処理手順について説明する。ボス形状の仕様を適用する手順は、まず、面分のラベル情報で Boss-Hole の面分を選択し、面分構成から円周方向線分を特定し、次に、特定した線分で構成される円周を等間隔で 6 分割する節点を配置、その後、配置した節点を固定条件として CAE プリソフトウェアの基本機能である面分ごとの自動メッシ

メッシュ機能により、ボス形状の穴構成面分に FE メッシュを生成した。また、リブ形状の仕様を適用する手順は、まず、面分のラベル情報で Rib-Top の面分を選択し、面分構成からリブ長手方向に直行する線分を特定し、次に、特定した線分上に互いに等直線距離となる節点を配置、その後、配置した節点を固定条件として、先ほどと同様に CAE プリソフトウェアの自動メッシュ機能により、リブ上部形状の構成面分に FE メッシュを生成した。これらの仕様を適用した特徴形状部位の FE メッシュを固定条件とし、CAE プリソフトウェアの自動メッシュ機能を用いて、CAD モデル全体に対して FE メッシュを生成した。

これら手順 1~4 の結果が示すように、手法 2 で特徴認識して出力したラベル付き点群から、CAD モデル上の面分にラベル割付けし、その面分ラベル情報と商用 CAE プリソフトウェアのマクロ機能を用いることで、仕様に適合した FE メッシュを自動生成することができた。このことから、三次元点群と深層学習を用いた特徴形状認識技術により、作成手順逐次実行方式 FE メッシュ自動生成システムを実現できる可能性が高いことがわかった。ただし、仕様適合した FE メッシュを確実に生成するためには、CAD モデル上の面分ラベルを正確に割付けできる程度に三次元点群の認識精度を高める必要があり、これは今後の課題である。

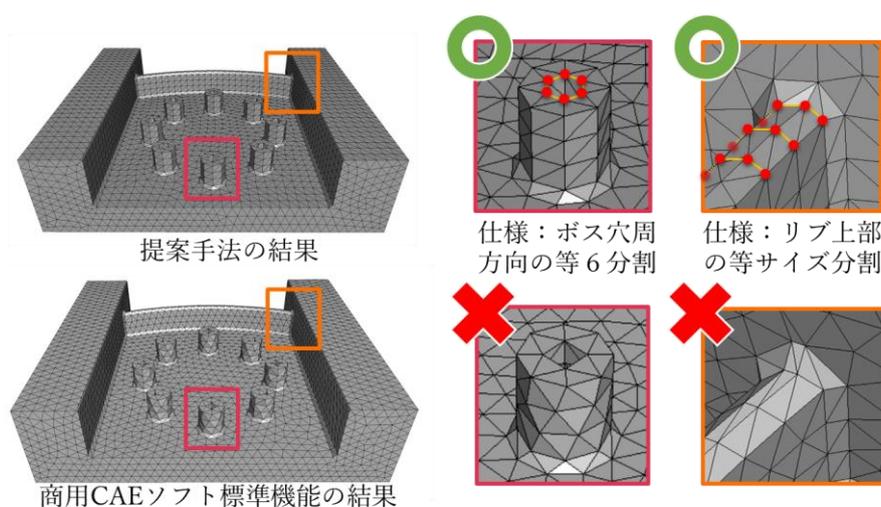


図 4-2-4 FE メッシュ生成の結果

4-3 仕様適合 FE メッシュによる構造解析

仕様適合及び非仕様適合の FE メッシュが解析結果に与える影響を確認することを目的として、4.2 節で作成した仕様適合 FE メッシュと、CAE プリソフトウェアの標準機能で生成した非仕様適合 FE メッシュに基づく 2 つの CAE モデルで構造解析を行った。

解析条件を図 4-3-1 に示す。左右両側の側面を完全拘束し、中央に配置された 8 つのボルト穴の内面とそれらの重心位置に設置した節点を剛体結合し、重心位置の節点に対して上方向静荷重を付加する。

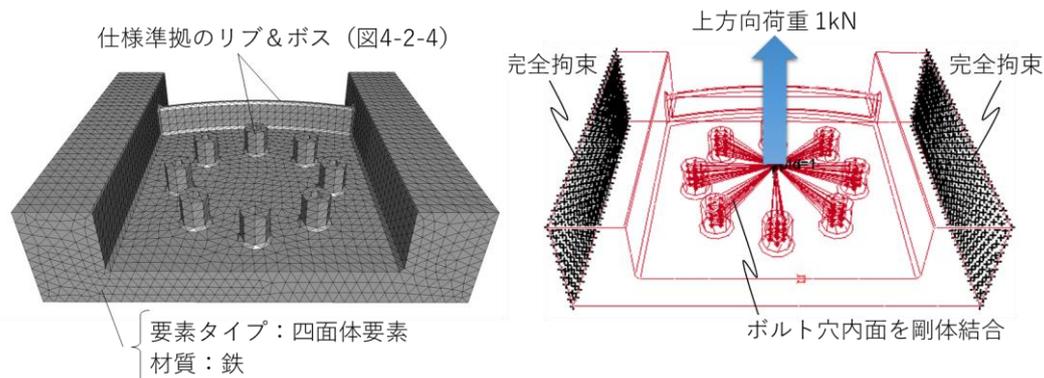


図 4-3-1 解析条件

構造解析結果を図 4-3-2 に示す。左右の側面が完全拘束されているため、側面に近いボス形状の根本に応力が集中しており、また、リップ形状の付近では剛性が高くなるため変位が小さく、図の手前側で変位が大きくなっている。この結果は、配置された特徴形状の荷重伝達構造から定性的に妥当と言える。

最大変位の位置及び値は、両モデルでほぼ同じであり、最大応力の位置もほぼ同じであったが、最大応力の値に 2 割の差異が生じた。そして、応力分布及び変位分布は僅かに異なる結果となった。これは、FE メッシュの違い、つまり荷重伝達構造の違いにより、変形モードが僅かに異なり、結果として

最大応力に 2 割の差異が生じたということである。

このように、仕様適合 FE メッシュを統一的に適用しなければ、モデル毎に解析結果が大きく異なる可能性があり、CAE による性能評価結果が不安定になる。特に、このケースにおいては、最大応力が 2 割異なる。仕様適合モデルの実機相関が取れていて実機相当の結果であると仮定した場合、非仕様適合モデルを用いた評価では、構造が必要以上に強固となり、質量が大きくなる。このケースとは逆に、応力が低く出る場合には、解析上、軽量の構造にすることが可能になるが、実機では強度に余裕が無く、製品不具合につながりかねない。このようなケースを防止するためにも、実機相関を取ることによって決定された仕様を統一的に適用した CAE モデルにより、解析結果の精度を保証することが重要である。そのような仕様適合 CAE モデルを効率よく構築するうえで、本研究で提案する特徴形状認識技術は重要な役割を果たすと考える。

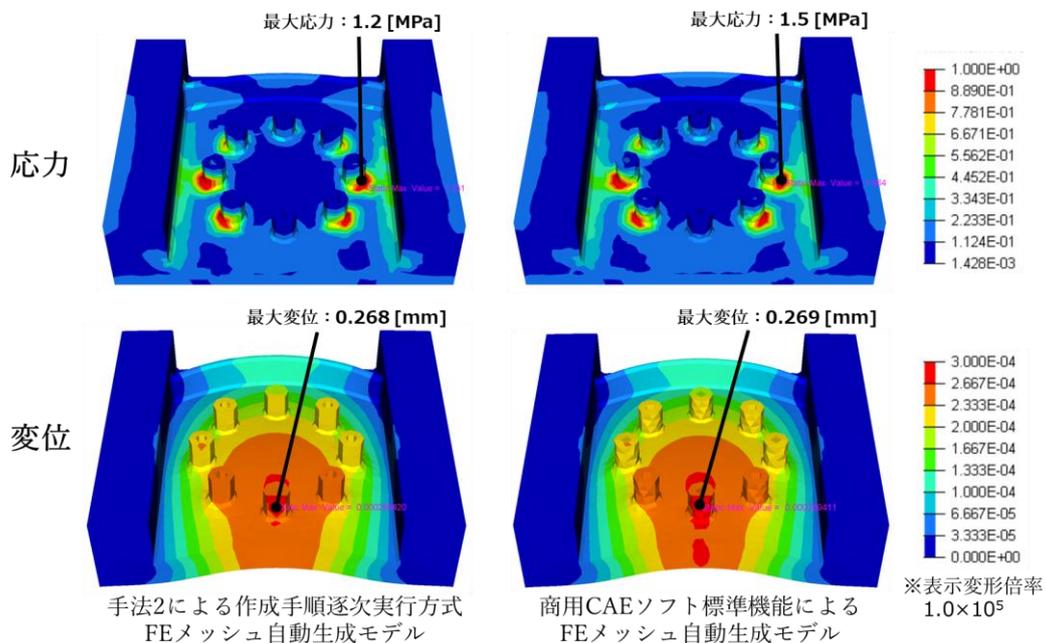


図 4-3-2 構造解析結果

4-4 PDQ 劣化部を含む CAD モデルを用いた

FE メッシュ生成

製品開発現場では、開発フェーズにより CAD モデルのつくり込み度合いが異なり、特に初期フェーズにおいては、PDQ 劣化部が含まれる場合がある。また、自動車は部品点数が多く、全ての部品で CAD モデル品質を完全に抑制できない場合もある。そして、PDQ 劣化部を含む CAD モデルに対し、商用 CAE プリソフトウェアの標準機能で CAE モデルを生成する場合、微小な要素や割れを修正しなければならず労力がかかる。そのため、ここでは、PDQ 劣化部を含む CAD モデルに対する FE メッシュ生成について検証する。

検証モデルとしては、図 4-4-1 に示すように、第 3 章の検証実験②で使用したモデル A のリブフィレット部に意図的に微小面分を入れたモデルを用意した。

上記モデルに対して、商用 CAE プリソフトウェアの標準機能で FE メッシュを生成した結果を図 4-4-2 に示す。図からわかるように、微小面分領域のメッシュが細かく分割されている。そのため、この FE メッシュを仕様に適合させるためには、手動による FE メッシュ修正が必要になる。

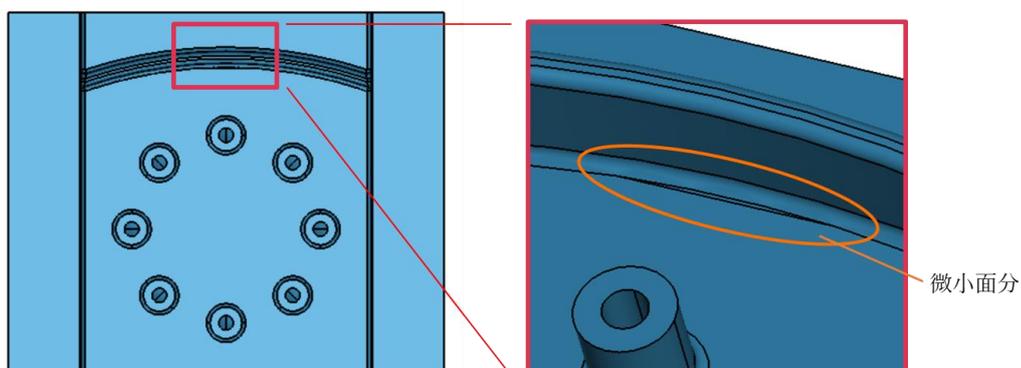


図 4-4-1 PDQ 劣化部を含む検証用 CAD モデル

一方，手法 2 で形状認識した結果を用いた作成手順逐次実行方式 FE メッシュ自動生成の結果を図 4-4-3 に示す．ここで，ラベル付き点群から CAD モデル上の各面分にラベル割付けする処理の際に，微小面分に割当てられたラベルを用いて，隣接する同ラベルの面分に微小面分を統合する処理を，4-2 節での同処理に対して加えている．図からわかるように，仕様適合 FE メッシュの生成に成功した．したがって，本研究で提案した三次元点群と深層学習を用いた自由曲面特徴形状認識手法は，PDQ の問題を含む入力 CAD モデルに対しても頑健に動作し，後工程である作成手順逐次実行方式 FE メッシュ自動生成に対して有効であることがわかった．

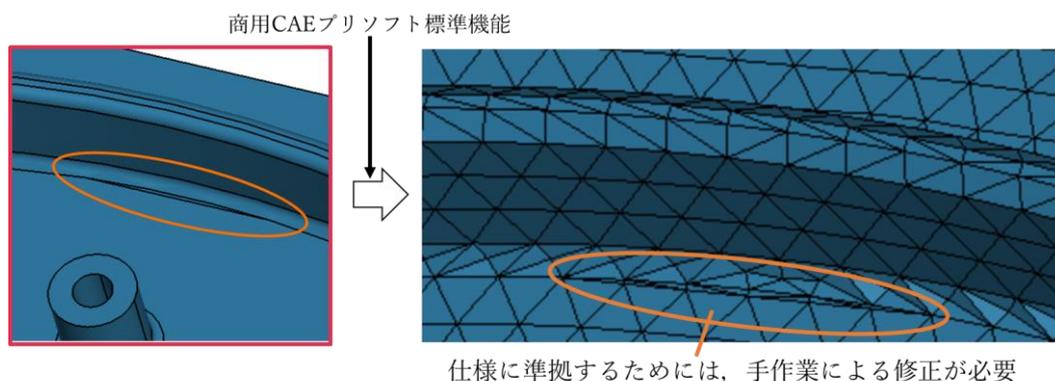


図 4-4-2 PDQ 劣化部を含む CAD モデルに対する商用 CAE プリソフト
トウェア標準機能による FE メッシュ生成

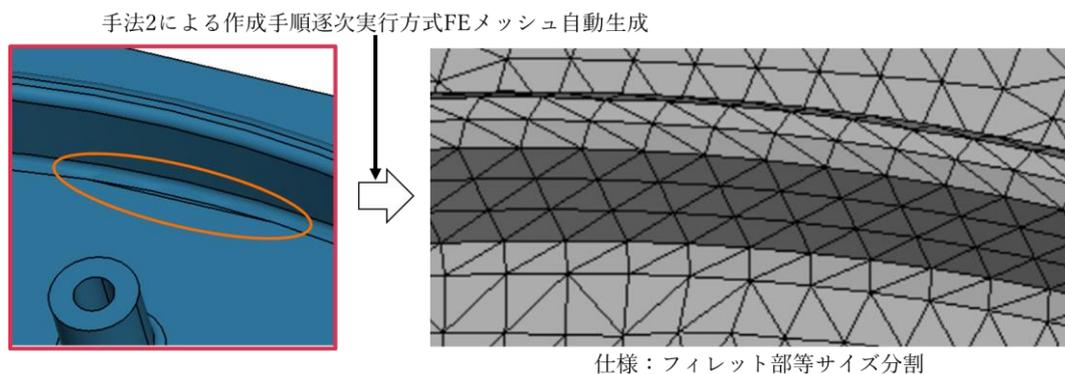


図 4-4-3 PDQ 劣化部を含む CAD モデルに対する手法 2 による作成
手順逐次実行方式 FE メッシュ自動生成

ただし，点群密度が不十分で微小面分にポイントが投影されずラベルを特定できない場合や，認識結果のラベル精度が不十分である場合には，この方法により FE メッシュを自動生成することはできない．これは，実装にあたっての今後の課題である．

4-5 まとめと今後の課題

本章では，特徴形状認識後のプロセスである FE メッシュ自動生成に関わる基礎的な検証により，CAE モデル自動生成システムの実現性を確認することができた。

本章における成果を以下にまとめる。

- (1) 手法 1 の特徴形状認識結果に基づくマッピング方式 FE メッシュ自動生成の実現性を示した。

第 2 章の検証実験②③④の認識結果として出力された射影変換行列を用いることで，各参照特徴形状と関連付いた FE メッシュを入力 CAD モデル上にマッピングできることを確認し，手法 1 によるマッピング方式 FE メッシュ自動生成の実装が可能であることを示した。

- (2) 手法 2 の特徴形状認識結果に基づく作成手順逐次実行方式 FE メッシュ自動生成の実現性を示した。

第 3 章の検証実験②③の認識結果として出力されたラベル付き点群と，商用 CAE プリソフトウェアのマクロ機能を用いて，入力 CAD モデル上の各面分にラベル付けを行い，そのラベル情報に基づいて仕様適合 FE メッシュを自動生成できることを確認し，手法 2 による作成手順逐次実行方式 FE メッシュ自動生成の実装が可能であることを示した。

- (3) 仕様適合 FE メッシュ生成の必要性を示した。

4.2 節で作成した仕様適合 FE メッシュと，CAE プリソフトウェアの標準機能で生成した非仕様適合 FE メッシュを用いた構造解析で，結果に明確な差異が生じることを確認した。これにより，実機相関を取ることと決定された仕様を統一的に適用した CAE モデルにより，解析結果

の精度を保証することが重要であり、また、製品品質保証のうえで重要であることを改めて示した。

(4) PDQ 劣化部を含む CAD モデルを用いて FE メッシュ自動生成が可能であることを示した。

第 3 章の検証実験②の認識結果として出力されたラベル付き点群を用いて、PDQ 劣化部を含む入力 CAD モデル上に FE メッシュを自動生成できることを確認した。これにより、離散的形状表現である三次元点群を活用することにより、特徴形状認識だけでなく、その後の FE メッシュ自動生成においても、頑健な動作を実現できる可能性を示した。

一方で、今後の課題として以下を確認することができた。

(1) 手法 1 として、1つの参照特徴形状から、類似するが比較的形状が乖離する特徴形状に対して精度よくマッピングができるよう射影変換行列の精度を高めること。

(2) 手法 2 として、CAD モデル上の面分ラベルを正確に割付けできる程度に三次元点群の認識精度を高めること。

(3) 手法 2 として、微小面分など PDQ 劣化部に対する安定的な FE メッシュ生成を可能にすること。

第 5 章

結論と今後の課題

5-1 結論

本研究では，CAE モデル自動生成を目的とし，離散的形状表現を活用した製品 CAD モデル上からの三次元特徴形状認識技術の開発を行った．離散的形状表現として三次元点群を採用することで，CAD モデルの位相構造や幾何形状に依存しない形状認識手法とし，また，形状認識後の FE メッシュ自動生成プロセスにおいて，既存技術で実装可能な 2 つの方式に対応した形状認識手法をそれぞれ開発した．第一の形状認識手法は，三次元点群と形状記述子を用いた類似特徴形状認識技術であり，製品形状 CAD モデル上に発見された特徴形状部位に対し，予め用意した仕様に適合した FE メッシュをマッピングする FE メッシュ自動生成方式を想定した特徴形状認識技術である．第二の形状認識手法は，三次元点群と深層学習を用いた自由曲面特徴形状認識技術であり，製品形状 CAD モデル上に識別された特徴形状と局所特徴領域に対し，規定された仕様に適合する FE メッシュの作成手順を，商用 CAE プリソフトウェアのマクロ機能を用いて逐次自動実行してゆく FE メッシュ自動生成方式を想定した特徴形状認識技術である．これらの形状認識手法の有効性を，単純形状を用いた基礎検証実験と製品形状に近い複雑形状を用いた検証実験により確認した．

本論文の第 2 章から第 4 章の各章で得られた結論を下記にまとめる．

- (1) 第 2 章では，仕様に適合した FE メッシュをマッピングする FE メッシュ自動生成方式を想定した特徴形状認識技術として，三次元点群と形

状記述子を用いた類似特徴形状認識技術を開発した。これは、データベース上に登録された参照特徴形状 CAD モデルの局所形状特徴量と、入力 CAD モデルの局所形状特徴量とのマッチングにより生成した局所形状特徴量マッチングペアを用いて、RANSAC アルゴリズムにより射影変換行列を推定し、非剛体且つパラメトリックな変形関係の類似特徴形状を抽出する技術である。本技術の開発により、参照特徴形状のデータベース追加登録のみによる抽出可能特徴形状バリエーションの拡大を可能とし、特徴形状バリエーションの違いに依存せず統一的且つ拡張性の高いアルゴリズムによる動作を実現した。また、パラメトリックな変形範囲において、等方スケーリング変換関係、直交異方スケーリング変換関係を含む射影変換関係にある類似特徴形状の抽出を可能にし、複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状 CAD モデルに対しての頑健動作を実現した。さらに、CAD モデルに依存する位相構造や幾何表現形式を陽に持たない離散的形状表現を用いることで、CAD モデルの構成要素に依存しないアルゴリズムとし、PDQ劣化部を含む CAD モデルや、複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状 CAD モデルに対しての頑健動作を実現した。

- (2) 第 3 章では、規定された仕様に適合する FE メッシュの作成手順を、商用 CAE プリソフトウェアのマクロ機能を用いて逐次自動実行していく FE メッシュ自動生成方式を想定した特徴形状認識技術として、三次元点群と深層学習を用いた自由曲面特徴形状認識技術を開発した。これは、入力 CAD モデル上の特徴形状を、パラメトリック CAD で大量生成した単体特徴形状を用いてトレーニングした深層学習ネットワークにより、特徴形状クラス及び局所特徴領域のラベルを各ポイントに割り付けた点群を出力する技術である。本技術の開発により、認識可能な特徴形状のバリエーションを拡大する際、トレーニングデータセットに新たな特徴形状を追加し、深層学習ネットワークを再トレーニ

ングすることで、特徴形状バリエーションの違いに依存せず統一的且つ拡張性の高いアルゴリズムによる特徴形状認識を実現し、離散的形状表現である三次元点群を用いることで、PDQ劣化部を含むCADモデルに対する頑健動作を実現した。また、Multi-Scale Bounding BoxとNon-Maximum Suppressionを組合せた手法により、パラメトリックCADで大量生成可能な単体特徴形状による深層学習アプローチを実現し、複雑で滑らかな曲面で構成された特徴形状が含まれる製品形状CADモデルに対しての頑健動作を実現した。

- (3) 第4章では、提案手法の形状認識結果を前提としたFEメッシュ自動生成の実現性を検証した。手法1である三次元点群と形状記述子を用いた類似特徴形状認識技術により出力した、参照特徴形状と類似する入力CADモデル上の特徴形状との間の射影変換行列を用いて、参照特徴形状に関連付いたFEメッシュを入力CADモデル上にマッピングすることが可能であることが確認できた。また、データベース上に参照特徴形状のバリエーションを増やすことで、特徴形状抽出の精度が上がり、FEメッシュのマッピング精度も高くなることが確認できた。次に、手法2である三次元点群と深層学習を用いた自由曲面特徴形状認識技術の出力結果であるラベル付き三次元点群を用いて、CADモデル上の各面分のラベルを特定し、商用CADプリソフトウェアのマクロ機能を用いて面分ラベル情報を参照し、標準コマンドを逐次自動実行することで、仕様適合FEメッシュを自動生成できることが確認できた。さらに、仕様適合FEメッシュと非仕様適合FEメッシュによる構造解析を行い、それらの結果の差異から、仕様適合FEメッシュの必要性を確認できた。また、PDQ劣化部を含むCADモデルに対しFEメッシュ自動生成を試みた結果、離散的形状表現である三次元点群を用いたことにより、形状認識プロセスにおいてだけでなく、その後のFEメッシュ自動生成プロセスにおいても、PDQ劣化部を含むCADモデルに対してFEメッシュ自動生成が可能であることが確認できた。

以上の結論を総括すると、本論文は、製品形状の離散的形状表現、及びその表現上で動作する形状記述子や深層学習を活用して、デジタル性能評価の信頼性を担保する仕様適合 CAE モデルの自動生成に必要な不可欠となる三次元特徴形状認識技術を新たに実現し、その工学的有効性を実験的に検証したものであると結論付けられる。

5-2 今後の課題

本論文で提案した手法に対する今後の課題を以下に述べる。

- (1) 手法 1 である三次元点群と形状記述子を用いた類似特徴形状認識技術において、同一断面が一方向に続く形状及び軸対称形状の安定的な抽出方法を開発する必要がある。また、1つの参照特徴形状から、類似するが比較的形状が乖離する特徴形状に対しても精度よくマッピングができるよう射影変換行列の精度を高める必要がある。さらに、処理高速化のため、CAD モデルから直接的に局所形状記述子を生成する手法を構築する必要がある。
- (2) 手法 2 である三次元点群と深層学習を用いた自由曲面特徴形状認識技術において、CAD モデル上の面分ラベルを正確に割付けできる程度に三次元点群の認識精度を高めることが必要であり、特に、特徴形状境界付近における認識精度を高める必要がある。また、対象とする形状群に対して高い認識精度を持つ深層学習ネットワークを構築するため、最適なトレーニングデータセットを効率的に構築する手法が必要である。
- (3) CAE モデル自動生成システムを実現するにあたり、形状認識プロセスだけではなく、FE メッシュ自動生成プロセスまでを含めた一連のプロセスの実装における具体的な課題を解決していく必要がある。たとえば、上記(1)(2)に述べた通り、FE メッシュ自動生成プロセスへの入力情報精度、つまり、形状認識精度の向上が必要であり、また、手法 2 においては、微小面分など PDQ 劣化部に対する安定的な FE メッシュ生成手法を開発する必要がある。

参考文献

- [Ankerst99] Ankerst, M.; Kastenmiller, G.; Kriegel, HP.; Seidl T.: 3D shape histograms for similarity search and classification in spatial databases, *Lecture Notes in Computer Science*, 1651, 1999, 207-226. https://doi.org/10.1007/3-540-48482-5_14
- [Attene10] Attene, M.; Marini, S.; Spagnuolo, M.; Falcidieno, B.: The Fast Reject Schema for Part-in-Whole 3D Shape Matching, *Eurographics Workshop on 3D Object Retrieval*, 2010, 23-30. <http://dx.doi.org/10.2312/3DOR/3DOR10/023-030>
- [Boussuge15] Boussuge, F.; Leon, J.-C.; Hahmann, S.; Fine, L.: Idealized models for FEA derived from generative modeling processes based on extrusion primitives, *Engineering with Computers*, 31(3), 2015, 513-527. <http://doi.org/10.1007/s00366-014-0382-x>
- [Cai18] Cai, N.; Bendjebba, S.; Lavernhe, S.; Mehdi-Souzani, C.; Anwer, N.: Freeform machining feature recognition with manufacturability analysis, *Procedia CIRP*, 72, 2018, 1475-1480. <https://doi.org/10.1016/j.procir.2018.03.261>
- [Drost10] Drost, B.; Ulrich, M.; Navab, N.; Ilic, S.: Model globally, match locally: Efficient and robust 3d object recognition, 2010 *IEEE Conference on Computer Vision and Pattern Recognition*, 2010, 998-1005. <https://doi.org/10.1109/CVPR.2010.5540108>

- [Guo20] Guo, Y.; Wang, H.; Hu, Q.; Liu, H.; Liu, L.; Bennamoun, M.: Deep Learning for 3D Point Clouds: A Survey, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020. <https://doi.org/10.1109/TPAMI.2020.3005434>
- [Gupta12] Gupta, R.K.; Gurumoorthy, B.: Automatic extraction of free-form surface features (FFSFs), *Computer-Aided Design*, 44(2), 2012, 99-112. <https://doi.org/10.1016/j.cad.2011.09.012>
- [Han00] Han, J.; Pratt, M.; Regli, W.C.: Manufacturing feature recognition from solid models: a status report, *IEEE Transactions on Robotics and Automation*, 16(6), 2000, 782-796. <https://doi.org/10.1109/70.897789>
- [Hansch14] Hansch, R.; Weber, T.; Hellwich, O.: Comparizon of 3D interest point detectors and descriptors for point cloud fusion, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2(3), 2014, 57-64. <https://doi.org/10.5194/isprsannals-II-3-57-2014>
- [Harik17] Harik, R.; Shi, Y.; Beak, S.: Shape Terra: mechanical feature recognition based on a persistent heat signature, *Computer-Aided Design and Applications*, 14(2), 2017, 206-218. <http://dx.doi.org/10.1080/16864360.2016.1223433>
- [Hidaka15] Hidaka, N.; Michikawa, T.; Yabuki, N.; Fukuda, T.; Motamedi, A.: Creating product models from point cloud of civil structures based on geometric similarity, *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(4), 2015, 137-141. <https://doi.org/10.5194/isprsarchives-XL-4-W5-137-2015>

- [Ip02] Ip, C.Y.; Lapadat, D.; Sieger, L.; Regli, W.C.: Using shape distributions to compare solid models, *Proceedings of the 7th ACM Symposium on Solid Modeling and Applications (SMA '02)*, 2002, 273-280. <https://doi.org/10.1145/566282.566322>
- [Itskovich10] Itskovich, A.; Tal, A.: Surface partial matching and application to archaeology, *Computers & Graphics*, 35(2), 2010, 334-341. <https://doi.org/10.1016/j.cag.2010.11.010>
- [Iyer05] Iyer, N.; Jayanti, S.; Lou, K.; Kalyanaraman, Y.; Ramani, K.: Three-dimensional shape searching: state-of-the-art review and future trends, *Computer-Aided Design*, 37(5), 2005, 509-530. <https://doi.org/10.1016/j.cad.2004.07.002>
- [Koenderink92] Koenderink, J.J.; Doorn, A.J.: Surface shape and curvature scales, *Image and Vision Computing*, 10(8), 1992, 557-564. [https://doi.org/10.1016/0262-8856\(92\)90076-F](https://doi.org/10.1016/0262-8856(92)90076-F)
- [Lai18] Lai, J.-Y.; Wang, M.-H.; Song, P.-P.; Hsu, C.-H.; Tsai, Y.-C.: Recognition and Decomposition of Rib Features in Thin-shell Plastic Parts for Finite Element Analysis, *Computer-Aided Design and Applications*, 15(2), 2018, 264-279. <https://doi.org/10.1080/16864360.2017.1375678>
- [Lankalapalli97] Lankalapalli, K.; Chatterjee, S.; Chang, T.C.: Feature recognition using ART2: A self-organizing neural network, *Journal of Intelligent Manufacturing*, 8(3), 1997, 203-214. <https://doi.org/10.1023/A:1018521207901>

- [Limaye20] Limaye, A.; Mathew, M.; Nagori, S.; Swami, P.K.; Maji, D.; Desappan, K.: SS3D: Single Shot 3D Object Detector. arXiv:2004.14674v2
- [Liu16] Liu, W.; Anguelov, D.; Erhan, D.; Szegedy, C.; Reed, S.; Fu, C.Y.; Berg, A.C.: SSD: Single Shot MultiBox Detector, European Conference on Computer Vision, 2016, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- [Liu09] Liu, Y.; Pu, J.; Zha, H.; Liu, W.; Uehara, Y.: Thickness histogram and statistical harmonic representation for 3D model retrieval, 3D Data Processing, Visualization and Transmission, Thessaloniki, 2004.
- [Lu01] Lu, Y.; Gadh, R.; Tautges, T.J.: Feature based hex meshing methodology: feature recognition and volume decomposition, Computer-Aided Design, 33(3), 2001, 221-232. [https://doi.org/10.1016/S0010-4485\(00\)00122-6](https://doi.org/10.1016/S0010-4485(00)00122-6)
- [Nagase13] Nagase, M.; Akizuki, S.; Hashimoto, M.: Reliable object recognition using 3-D feature points for minimizing its mismatching, Journal of The Japan Society for Precision Engineering, 79(11), 2013, 1058-1062. <https://doi.org/10.2493/jjspe.79.1058>
- [Nezis97] Nezis, K.; Vosniakos, G.: Recognizing 2 1/2D shape features using a neural network and heuristics, Computer-Aided Design, 29(7), 1997, 523-539. [https://doi.org/10.1016/S0010-4485\(97\)00003-1](https://doi.org/10.1016/S0010-4485(97)00003-1)

- [Onodera19] Onodera, M.; Hariya, M.; Kongo, C.; Shintani, M.; Ka, K.; Watanuki, K.: Development of high precise similar sub-part search technique for automatic mesh generation reusing proven models, Transactions of The Japan Society of Mechanical Engineers, 85(880), 2019, 19-138. <https://doi.org/10.1299/transjsme.19-00138>
- [Osada02] Osada, R.; Funkhouser, T.; Chazelle, B.; Dobkin, D.: Shape distributions, ACM Trans. Graph, 21(4), 2002, 807-832. <https://doi.org/10.1145/571647.571648>
- [Pham20] Pham, T.Q.: Non-maximum Suppression Using fewer than Two Comparisons per Pixel, Advanced Concepts for Intelligent Vision Systems, 2010. https://doi.org/10.1007/978-3-642-17688-3_41
- [Poo13] Poo, M.; Buysee, E.; Carmona, R.; Coto, E.; Navarro, H.: GPU-accelerated Polyp Detection in Virtual Colonoscopy, CLEI electronic journal, 16(2), 2013, 3-3. ISSN 0717-5000
- [Prabhakar92] Prabhakar, S.; Henderson, M.R.: Automatic form-feature recognition using neural-network-based techniques on boundary representations of solid models, Computer-Aided Design, 24(7), 1992, 381-393. [https://doi.org/10.1016/0010-4485\(92\)90064-H](https://doi.org/10.1016/0010-4485(92)90064-H)
- [Preddireddy20] Peddireddy, D.; Fu, X.; Wang, H.; Joung, B.G.; Aggarwal, V.; Sutherland, J.W.; Jun, B.G.: Deep learning based approach for identifying conventional machining processes from CAD data, Procedia Manufacturing, 48, 2020, 915-925. <https://doi.org/10.1016/j.promfg.2020.05.130>

- [Qi17-1] Qi, C.R.; Su, H.; Mo, K.; Guibas, L.J.: PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation, Proceedings of the IEEE Conference on CVPR, 2017, 652-660. <https://doi.ieeecomputersociety.org/10.1109/CVPR.2017.16>
- [Qi17-2] Qi, C.R.; Yi, L.; Su, H.; Guibas, L.J.: PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space, Proceedings of NIPS, 2017, 5105-5114. <https://arxiv.org/abs/1706.02413>
- [Rusu08] Rusu, R.B.; Marton, Z.C.; Blodow, N.; Beetz, M.: Persistent point feature histograms for 3D point clouds, Proceedings of the 10th International Conference on Intelligent Autonomous Systems, 2008.
- [Rusu09] Rusu, R.B.; Blodow, N.; Beetz, M.: Fast point feature histograms (FPFH) for 3D registration, Proceedings of the IEEE International Conference on Robotics and Automation, Kobe, Japan, May 12-17 2009.
- [Rusu09-2] Rusu, R.B.; Semantic 3D object maps for everyday manipulation in human living environments, Institute for Computer Science at the Technical University of Munich, Chapter 6, 2009.
- [Shi18] Shi, Y.; Zhang, Y.; Baek, S.; Backer D.W.; Harik, R.: Manufacturability analysis for additive manufacturing using a novel feature recognition technique, Computer-Aided Design and Applications, 15(6), 2018, 941-952. <https://doi.org/10.1080/16864360.2018.1462574>

- [Su18] Su, H.; Jampani, V.; Sun, D.; Maji, S.; Kalogerakis, E.; Yang, M. H.; Kautz, J.: SPLATNet: Sparse Lattice Networks for Point Cloud Processing, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2018, 2530-2539. <https://doi.org/10.1109/CVPR.2018.00268>
- [Sunil08] Sunil, V.B.; Pande, S.S.: Automatic recognition of features from freeform surface CAD models, Computer-Aided Design, 40(4), 2008, 502-517. <https://doi.org/10.1016/j.cad.2008.01.006>
- [Sunil09] Sunil, V.B.; Pande, S.S.: Automatic recognition of machining features using artificial neural networks, International Journal of Advanced Manufacturing Technology, 41, 2009(9-10), 932-947. <https://doi.org/10.1007/s00170-008-1536-z>
- [Takaishi20] Takaishi, I.; Kanai, S.; Date, H.; Takashima, H.: Free-Form feature classification for finite element meshing based on shape descriptors and machine learning, Computer-Aided Design and Applications, 17(5), 2020, 1049-1066. <https://doi.org/10.14733/cadaps.2020.1049-1066>
- [Tangelder08] Tangelder, J.W.H.; Veltkamp, R.C.: A survey of content based 3D shape retrieval methods, Multimedia Tools Applications, 39, 2008, 441-471. <https://doi.org/10.1007/s11042-007-0181-0>
- [Tombari10] Tombari, F.; Salti, S.; Stefano, L.D.: Unique Signatures of Histograms for Local Surface Description, Proceedings of the European Conference on Computer Vision 2010, Part 3, 2010, 356-369. https://doi.org/10.1007/978-3-642-15558-1_26

- [Wang17] Wang, M.-S.; Lai, J.-Y.; Hsu, C.-H.; Tsai, Y.-C.; Huang, C.-Y.: Boss Recognition Algorithm and Application to Finite Element Analysis, *Computer-Aided Design and Applications*, 14(4), 2017, 450-463. <http://doi.org/10.1080/16864360.2016.1257187>
- [Wohlkinger11] Wohlkinger, W.; Vincze, M.: Ensemble of shape functions for 3D object classification, *Proceedings of the IEEE International Conference on Robotics and Biomimetics*, 2011, 2987-2992. <https://doi.org/10.1109/ROBIO.2011.6181760>
- [Wu14] Wu, H.; Gao, S.: Automatic swept volume decomposition based on sweep directions extraction for hexahedral meshing, *Procedia Engineering*, 82, 2014, 136-148. <https://doi.org/10.1016/j.proeng.2014.10.379>
- [Xu15] Xu, S.; Anwer, N.; Mehdi-Souzani, C.: Machining Feature Recognition from In-Process Model of NC Simulation, *Computer-Aided Design and Applications*, 12(4), 2015, 383-392. <http://dx.doi.org/10.1080/16864360.2014.997634>
- [Yoshida01] Yoshida, H.; Nappi, J.: Three-dimensional computer-aided diagnosis scheme for detection of colonic polyps, *IEEE Transactions on Medical Imaging*, 20(12), 2001, 1261-1274. <https://doi.org/10.1109/42.974921>
- [Yu20] Yu, Y.; Wei, X.; Li, A.; Liu, J.G.; He, J.; Zhang, Y.J.: HexGen and Hex2Spline: Polycube-based Hexahedral Mesh Generation and Spline Modeling for Isogeometric Analysis Applications in LS-DYNA. [arXiv:2011.14213v1](https://arxiv.org/abs/2011.14213v1)

- [Yu21] Yu, Y.; Liu J.G.; Zhang Y.J.: HexDom: Polycube-Based Hexahedral-Dominant Mesh Generation. arXiv:2103.04183v2
- [Yuan18] Yuan, W.; Khot, T.; Held, D.; Mertz, C.; Hebert, M.: PCN: Point Completion Network, 2018 International Conference on 3D Vision, Verona, 2018, 728-737. <https://doi.org/10.1109/3DV.2018.00088>
- [Zhang18] Zhang, Z.; Jaiswal, P.; Rai, R.: FeatureNet: Machining feature recognition based on 3D Convolution Neural Network, Computer-Aided Design, 101, 2018, 12-22. <https://doi.org/10.1016/j.cad.2018.03.006>

謝辞

本論文は、北海道大学大学院 情報科学研究科 システム情報科学専攻 博士後期課程に在籍中の研究成果をまとめたものです。論文執筆にあたり、多くの方々からご指導並びにご協力をいただいたことに感謝の意を表します。

指導教官の金井理教授には、本研究に取り組む機会を与えていただき、また、学会誌への投稿及び国際会議での発表などの貴重な機会を与えていただきました。そして、それらの研究活動を通し、研究への取り組み方、研究者としての姿勢を学ぶことができました。特に、仕事との両立に難儀し研究が進捗しない時期には、多くの視点を持ち小さな成果を積み上げる粘り強さが研究者に必要であることを強く知る機会となりました。これらのご指導に心より感謝申し上げます。

本論文の審査にあたり、小野里雅彦教授には、副査をお引き受けいただき、また、的確なご助言とご指導をいただきました。ここに感謝申し上げます。伊達宏昭准教授には、副査をお引き受けいただき、また、審査におけるご助言とご指導をいただき、さらに、研究に必要なリソースをご準備いただいたり、朝まで話にお付き合いいただいたりと、幅広くご支援いただきました。ここに感謝の意を表します。

岸浪建史名誉教授には、博士後期課程に挑戦するきっかけをいただき、また、日々仕事と研究の両立で苦しむ中、長期間にわたり精神的な面で多くのサポートをいただきました。心より感謝申し上げます。

株式会社 A I S 北海道 藤澤義麿社長には、博士後期課程に挑戦する機会をいただき、また、予定していた期間に修了できなかったにも関わらず、長期間にわたり本研究活動を温かく見守ってくれました。そして、仕事においても、この期間に多くの貴重な機会をいただき、仕事と研究の両面で多くのことを学ばせていただきました。心より感謝申し上げます。同社 故井潟博彦取締役には、博士後期課程への挑戦を応援していただきました。ここに

福をお祈りするとともに，心より感謝申し上げます．同社社員である石垣麗子さん，中村紋さん，鈴木秀記さん，葛西涼太さん，藤浦徹さん，泰地哲史さんには，本研究のモデル作成に協力していただき，山元達矢さんには，計算環境の構築に協力していただきました．また，同社社員の皆さんには，目に見えない様々な形で本研究活動をサポートしていただきました．ここに感謝の意を表します．

最後に，いつも私を応援しサポートしてくれている妻と子供たちに心から感謝します．

研究業績

I. 査読付学会誌等

- 1) Takashima, H.; Kanai, S.: Shape Descriptor-Based Similar Feature Extraction for Finite Element Meshing, Computer-Aided Design and Applications, 18(5), 2021, 1080-1095.
<https://doi.org/10.14733/cadaps.2021.1080-1095>
- 2) Takashima, H.; Kanai, S.: Recognition of Free-form Features for Finite Element Meshing using Deep Learning, Computer-Aided Design and Applications, Computer-Aided Design and Applications, (2021/5/28 掲載決定済み, 印刷巻号未定)

II. 査読付国際会議プロシーディング

- 1) Takashima, H.; Kanai, S.: Shape Descriptor-Based Similar Feature Extraction for Finite Element Meshing, Proceedings of CAD'20, Barcelona, Spain, July 6-8, 2020, 297-301.
<https://doi.org/10.14733/cadconfP.2020.297-301>
- 2) Takashima, H.; Kanai, S.: Recognition of Free-form Features for Finite Element Meshing using Deep Learning, Proceedings of CAD'21, Barcelona, Spain, July 5-7, 2021, 31-35.
<https://doi.org/10.14733/cadconfP.2021.31-35>

III. 国内学会

- 1) 高嶋英巖, 金井理, “CAE モデルデータ自動生成のための特徴形状認識手法の開発—SHOT 特徴量と非剛体変換を用いたサイズ違い及び歪みのある特徴形状の認識—”, 2018 年度精密工学会秋季大会学術講演会講演論文集, A01-3, 2018. https://doi.org/10.11522/pscjspe.2018A.0_5
- 2) 高嶋英巖, 金井理, “CAE モデルデータ自動生成のための類似特徴形状検索手法の開発”, 2020 年度精密工学会春季大会学術講演会講演論文集, C53, 2020. https://doi.org/10.11522/pscjspe.2020S.0_210

IV. 受賞

- 1) Takaishi, I.; Kanai, S.; Date, H.; Takashima, H.: Free-Form feature classification for finite element meshing based on shape descriptors and machine learning, *Computer-Aided Design and Applications*, 17(5), 2020, 1049-1066.
<https://doi.org/10.14733/cadaps.2020.1049-1066>
(Best Paper Award 受賞)