

配管系統接続部品の深層学習と SVM による分類精度評価

Evaluation of Classification Accuracy of Connecting Parts of Piping Systems
Using Deep Learning and SVM

○橋本侑弥*, 溝口知広*

○Yuya Hashimoto*, Tomohiro Mizoguchi*

*日本大学

*Nihon University

キーワード: 配管系統(Piping System), レーザースキャナ(Laser Scanner), 深層学習(Deep Learning), サポートベクターマシン(Support Vector Machine)

連絡先: 〒963-1165 福島県郡山市田村町徳定字中河原 1
日本大学 工学部 情報工学科 生産システム研究室
橋本侑弥, TEL: (024)956-8825, E-mail: ceyu17016@g.nihon-u.ac.jp

1 緒 言

産業プラントの設備更新, 及び定期的なメンテナンスを効率的に行うためには, 実際の設備を忠実に再現した 3D モデルが必要となる。しかしながら古い設備では 3D モデルが存在せず, 仮に存在したとしても実際の状況と異なっているといった問題が発生している。そのため, 実際の設備の 3 次元計測を行い, 取得した点群から設備の実際の状況を忠実に再現した 3D モデルを作成するアズビルトモデリングの要求が高まっている。産業プラントの場合, 特に配管系統のモデリングが要求される。配管系統は通常, Fig.1 に示すように, 配管の他に, 配管に接続される複数種類の部品から構成される。そのため配管系統のアズビルトモデリングにおいては, まず計測点群中の部品をそれぞれ認識し, これらを 3D モデルへと変換する処理が必要となる。

このアズビルトモデリングを目的とした研究例が多数報告されている[1]。しかしながらこれらの手法では, 表面積の大きなパイプや型鋼の抽出のみを目的としており, 表面積が小さく形状が複雑な接続部品の認識は行えていない。わずかに, Kawashima ら[2]や Son ら[3]の研究では接続部品の認識を行っ

ているが, 認識対象クラスがエルボ, T/Y-ジャンクション, レデューサといった, 形状が比較的シンプルなものに限定されるといった問題がある。なおこれらの手法では, 法線ベクトルや曲率といった局所的な形状特徴を手掛かりとしており, 形状が複雑なバルブやフランジ等への応用は難しい。

そこで本研究では, 配管系統の計測点群から, パイプや型鋼のみならず, 幅広いクラスの接続部品をも点群から自動認識する手法の開発を目的とする。本手法の基本的なアイデアは, 点群を画像化し, 機械学習を用いて抽出を行う点にある。特に深層学習を利用することで, 従来手法では困難であったバルブやフランジに対しても, 高精度な認識が可能となる。また画像サイズが小さい場合でも, 超解像処理を適用することで認識が可能となる。

本報では, 点群から接続部品の RGB 画像と反射強度画像を作成し, これらを深層学習と SVM (Support Vector Machine)を組み合わせた手法に利用することで, その分類精度を評価した。提案手法では点群から RGB 画像と反射強度画像を作成し, これを深層学習, 及び深層学習と SVM を組み合わせた手法に適用し, 分類を行った。分類対象は, バルブ

のハンドル部(以下バルブ), エルボ, フランジの3種類とした.

本研究では某所ボイラー室を Z+F 社の Imager 5010C にて取得した計測点群と, 日本大学工学部ボイラー室を FARO 社の Focus 3D にて取得した計測点群を使用した. 使用したスキャナの主なスペックを Table 1 に示し, 取得した計測点群の例を Fig.2 に示す.

Table 1 スキャナの主なスペック

	Imager5010C	Focus 3D
計測速度	1,000,000 点/秒	976,000 点/秒
計測距離	0.3~187m	0.6~120m
計測範囲	水平 360deg	水平 360deg
	垂直 320deg	垂直 305deg
計測角度ピッチ	0.072deg	0.036deg



Fig.1 配管系統の例(左からパイプ, エルボ, T ジャンクション, レデュース, フランジ, バルブ)



Fig.2 Imager5010C による 3 次元計測点群の例

2 実験の概要

本研究では, 点群から作成した RGB 画像と反射強度画像を, 深層学習, 及び深層学習と SVM を組み合わせた手法に適用した. その組み合わせは Table 2 に示すように 5 つのケースに分類される. それぞれの処理の概要を Fig.3 に示し, 詳細を以下に述べる.

- Case1 では RGB 画像を, Case2 では反射強度画像をそれぞれ深層学習に利用し, 特徴抽出から分類までを行った.
- Case3 では RGB 画像から, Case4 では反射強度画像から, それぞれ深層学習にて特徴ベクトル f_{RGB} , f_I を抽出する. この特徴ベクトルをそれぞれ SVM に適用し分

類を行った.

- Case5 では同様に f_{RGB} , f_I を抽出し, それらを結合して f_{RGBI} を作成し, これをもとに SVM にて分類を行う.

Table 2 実験の条件

	機械学習	画像の種類
Case1	深層学習	RGB
Case2	深層学習	反射強度
Case3	深層学習と SVM	RGB
Case4	深層学習と SVM	反射強度
Case5	深層学習と SVM	RGB と反射強度

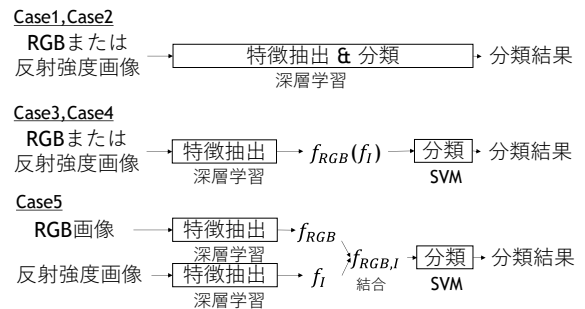


Fig.3 実験概要

3 提案手法

3.1 画像の作成

まず計測された点群のうち, 接続部品を目視で抽出した. 抽出した各点群の計測地点からの距離はおよそ 1m から 10m 程度である. その後, 円筒座標展開により RGB 画像, 反射強度画像をそれぞれ作成した. 画像サイズは最小で 29×29 ピクセル, 最大で 946×946 ピクセルであった. Fig.4 に作成した画像の一例を示す. その後, 作成した画像をバイキュービック法で 256×256 にリサイズした.




Fig.4 作成した画像の例 (上段: RGB 画像, 下段: 反射強度画像, 左: バルブ, 中: エルボ, 右: フランジ)

3.2 特徴抽出と分類

3.2.1 深層学習による分類

Case1 と Case2 では、深層学習にて特徴抽出から分類までを行った。ネットワークには AlexNet の簡略版を使用した。このネットワーク構成を Fig.5 に示す。畳み込み 5 層、プーリング 3 層、全結合 2 層から構成されている。ここでは入力層を Input, 畳み込み層を Conv, プーリング層を Pool, 全結合層を FC で示した。また学習回数はすべて 400,000 回に設定した。




Fig.5 使用したネットワークの構成

3.2.2 深層学習による特徴抽出

Case3 から Case5 においては、深層学習にて RGB 画像と反射強度画像からそれぞれ特徴ベクトル f_{RGB} と f_I を抽出した。これらは 1 つ目の全結合層 FC1 の 4,096 次元からなるベクトルである。また Case5 では、抽出した f_{RGB} と f_I を結合し、8,192 次元の特徴ベクトル f_{RGBI} を作成した。

3.3 SVM による分類

Case3 から Case5 では、深層学習にて抽出した特徴ベクトルを SVM に利用することで分類を行った。カーネルには RBF を使用し、パラメータはファインチューニングした。

4 実験結果

本実験では、バルブ、エルボ、フランジから、それぞれ RGB 画像と反射強度画像を、それぞれ 133 枚、127 枚、128 枚ずつ、合計で 776 枚作成した。このうち各クラスとも、RGB 画像と反射強度画像について各部品 100 枚、計 600 枚を学習用画像とし、その他をテスト用画像とした。各 Case における分類結果を Table 3 に示す。

4.1 RGB と反射強度画像での分類結果の比較

Table 3 に示すように Case1 と Case2 の深層学習のみを使用した場合には、RGB 画像の平均 f 値が 80.3% に対して、反射強度画像では 85.8% と高い値が得られた。一方で、Case3 と Case4 の深層学習と SVM を併用した場合は、RGB 画像の平均 f 値が 83.8% に対して、反射強度画像では 87.6% と高い値が得られ、こちらの場合でも反射強度画像を使用することで高い分類正解率が得られることが分かった。

4.2 深層学習と SVM の併用による分類率向上効果の検証

Case1 と Case3, Case2 と Case4 を比較すると、RGB 画像、反射強度画像ともに深層学習のみを使用するより、SVM を併用することで分類正解率が向上することが分かった。

4.3 RGB と反射強度画像の併用による分類率向上効果の検証

Case5 の結果より、RGB 画像と反射強度画像を併用することで、平均 f 値が 94.1% となり、それぞれを個別に使用した Case3, Case4 と比べ、分類正解率が向上することが分かった。

4.4 Case5 の分類結果

Case5 の分類結果の内訳を Table 4 に示す。それぞれの f 値を比較すると、バルブは 97.0%、エルボが 92.3%、フランジが 93.1% となり、クラス間の差は見られなかった。また分類に成功した画像と失敗した画像の例を Fig.6 に示す。

4.5 失敗の主な原因

失敗したバルブ画像は、Fig.6 に示すように、元の部品サイズが小さく、そのため画像化した際に画像サイズが 80×80 ピクセルと小さいものとなっており、Fig.6 の分類に成功した画像と比べて全体が白色である。バルブの学習データには白色のものはほとんどなく、分類データにおいては他に一切存在していなかった。また、学習データのフランジ画像では、色情報がこの画像と似ている画像が多数あった。このことから、解像度と色情報が原因でフランジに誤分類したものと考えられる。

失敗した 3 枚のエルボ画像では、元の部品

サイズは大きいものの、計測距離が6~8mと遠く、画像サイズが77×77ピクセルから121×121ピクセルと比較的小さかった。また、Fig.6に示したように失敗したエルボ画像ではオクルージョンによる計測点群の欠損があり、またFig.6に示す分類に成功したエルボ画像と比べて形状が不鮮明であった。

Fig.6に示す分類に失敗したフランジ画像では、部品形状が大きく歪んでおり、他のフランジ画像とは形状が大きく異なっている。また他と大きく異なり、色が暗く、紫に近い色をしていた。

以上から、分類失敗の主な原因として、1) 部品サイズが小さいため、または計測距離が遠いため画像解像度が低いこと、2) 色と形状が他と異なること、3) オクルージョンによる部品点群の欠損があることが考えられる。

Table 3 実験結果

	バルブ	エルボ	フランジ	平均 f 値
Case1	86.5%	78.9%	75.4%	80.3%
Case2	90.1%	82.1%	85.2%	85.8%
Case3	88.2%	83.3%	83.4%	83.8%
Case4	94.1%	83.0%	85.7%	87.6%
Case5	96.7%	92.3%	93.1%	94.1%

Table 4 Case5 における分類結果の内訳

		正解			
		バルブ	エルボ	フランジ	適合率
分類 結果	バルブ	32	1	0	96.7%
	エルボ	0	24	1	96.0%
	フランジ	1	2	27	90.0%
	再現率	96.7%	88.9%	96.4%	平均 f 値
	f 値	96.7%	92.3%	93.1%	94.1%

5 結言

本研究では、配管システムのアズビルトモデリングを目的とし、深層学習とSVMによる接続部品の分類精度評価を行い、その有効性を確認した。今後は点群から分類した部品を自動抽出する手法の開発などを行う予定である。

分類に成功 分類に失敗




Fig.6 分類に成功した画像と失敗した画像の例 (上:バルブ, 中:エルボ, 下:フランジ)

謝 辞

本研究で使用した点群データは、新菱冷熱工業株式会社様よりご提供頂きました。また、FARO Focus3Dは北海道大学の金井理教授のご厚意で使用させていただきました。ここに記して謝意を表します。

参考文献

- [1] Tomohiro Mizoguchi, Tomokazu Kuma, Yoshikazu Kobayashi, and Kenji Shirai, "Manhattan-World Assumption for As-built Modeling Industrial Plant," Key Engineering Materials, Vol.523-524, pp350-355, 2012.
- [2] Kazuaki Kawashima, Satoshi Kanai, and Hiroaki Date, "As-built modeling of piping system from terrestrial laser-scanned point clouds using normal-based region growing," Journal of Computational Design and Engineering Vol.1, pp.13-26, 2014.
- [3] Hyojoo Son and Changwan Kim, "Automatic segmentation and 3D modeling of pipelines into constituent parts from laser-scan data of the built environment," Automation in Construction, 68, pp.203-211, 2016.