

工業設備の大規模点群からの部材形状の抽出と認識（第2報）

電気通信大学 ○重田 航平, 増田 宏

1. 緒言

地上型レーザスキャナ (TLS) で取得された工業設備の点群から 3 次元モデルを作成する手法について、これまで多くの研究がなされてきた。しかし、計測場所が限られるため不完全な点群から形状再構成を行う必要がある。また、点群密度や計測精度が不十分なため、検出できる曲面は平面や円柱、回転体など形状が簡単なものに限定されるという問題がある。

我々のこれまでの研究では、点群から平面と円柱を検出し、それらの組み合わせから部材を同定し、形状再構成を行う手法を開発している[1]。しかし、曲面の組み合わせから同定することができる部材の種類は限られており、汎用性が高くないという問題があった。

そこで、前報では、点群から RGB 画像を生成し、機械学習を用いた部材認識手法を検討した。しかし、検証した部材がエルボとフランジの 2 種類と種類が少なく、精度も十分ではなかった。本報では、新たに反射強度画像と Depth 画像も用いて画像生成手法の改善を行い、また、CNN (Convolutional Neural Network) で生成される複数の特徴量を合成することで、部材の種類を増やしても精度が維持できるかを検証する。

2. 手法の概要

本研究では、TLS により計測した高密度点群から作成した画像を用いて、機械学習によって部材の認識を行うことを考える。点群は RGB カラー、反射強度、スキャナからの距離を属性として保持しているものとする。

まず前報[2]と同様に透視投影画像を作成する。図 1 のように点群を球面座標系に変換し、2 次元平面に投影することで球面画像が作成できるが、球面画像では画像に歪みが生じ、物体の直線性が保存されない。この歪みは、特に、画面の上部と下部で大きくなる。これを解消するために、図 2 左のように、仮想的な透視投影面を作成して、球面座標 (θ, ϕ) を透視投影面の座標 (I, J) に変換する。透視投影画像は直線性を保存するため、形状に歪みのない部材の画像を作成することができる。

透視投影画像では、画素に与える数値によって RGB、Intensity、depth 画像の 3 種類が生成できる。この 3 種類の透視投影画像に対し CNN を適用して、画像を特徴量ベクトルに変換し、部材の同定を行う。この時データ数が少ないため、画像処理と CAD データによりデータを拡張し精度を向上させる。また、2 次元特徴量と 3 次元特徴量を統合するために各画像から特徴量を抽出する。それらを統合することで分類の精度が向上するか検証する。

3. RGB, Intensity, Depth 画像の作成

RGB は、0 以上 255 以下の 3 個の整数値 $[R, G, B]$ で表現される。Intensity は、レーザスキャナの機種に応じた解像度を持つが、ここでは、0 以上 255 以下の整数値に正規化する。これらの数値を各画素で与えることで、RGB 画像と Intensity 画像を作成する。

これらの画像は点群に基づいて作成されているため、各画素には点群の座標を割り当てることができる。そのため、画像上で隣接する点の距離を調べることで、連続した面上の点を抽出することができる。ここでは、図 3 のように連結な面のみを抽出し、背景のない画像を作成して物体認識を行う。

Depth 画像は、スキャナ原点から各画素の座標までの距離を 0~255 に正規化して作成する。この場合も、連結な面のみを抽出する。

4. データの拡張

4.1 画像処理を用いたデータ拡張

作成したデータセットでは、学習データが少なく十分な精度を得られない可能性が高い。そのため、画像処理によってデータを拡張することを考える。図 4 のように元の画像に対して回転、輝度値の変更、白黒のノイズ付加、反転の処理を施して 1 枚の画像を 15 枚に拡張する。

4.2 CAD モデルからの Depth 画像の作成

Depth 画像は各点のスキャナ原点からの距離を用いて作成する。よって実際の点群データを利用せず、自作した CAD モデルを用いて Depth 画像を作成することができる。

まず、3D CAD を用いて、厚みのないサーフェスモデルを作成する。形状が一意に定まる標準部材は、規格にしたがって 3D モデルを作成する。一方で、バルブやレギュレーサなど、主要寸法以外は規定されていない部材も存在する。その場合には、現況に準じた形状として 3D モデルを作成した。

Depth 画像は、3D モデルの位置姿勢に依存する。一つの 3D モデルから、その位置姿勢を様々に変化させることで、多数の Depth 画像を生成することができる。Depth 画像は、図 5 のように、3D モデルの面上に密な点群を生成し、それらを透視投影面に投影することで作成した。




図 1 球面座標系への投影




図 2 透視投影画像への変換




図 3 背景を消去した画像

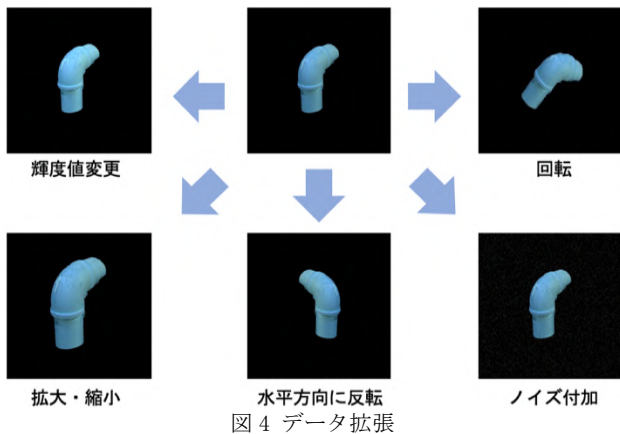


図4 データ拡張




図5 Depth 画像の作成

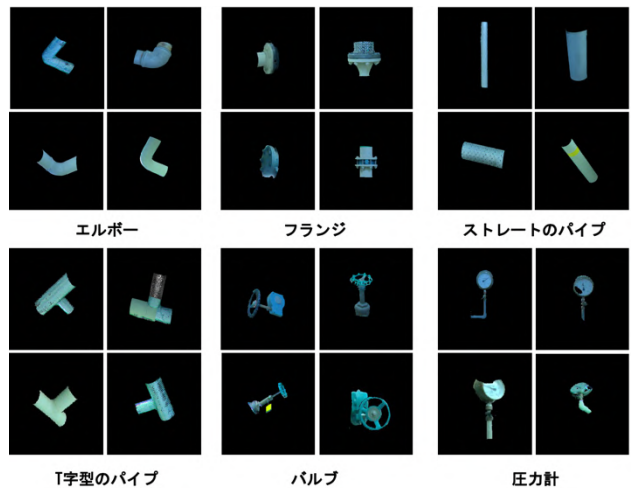


図6 データセット

5. 機械学習による画像の分類

5.1 機械学習による部材の同定

本研究では CNN として、ImageNet による学習済みの VGG16 を利用し、本研究において点群から生成した 3 種類の部材の画像をそれぞれ転移学習によって学習させる。それによって、3 種類の分類器が生成される。

5.2 特徴量の統合

本研究で生成した 3 種類の画像は、単独で用いるよりも組み合わせで用いる方が、認識率が向上すると考えられる。そこで、各分類器から抽出した特徴量に Random Forest を用い流ことで、3 種類の画像の特徴量を統合することを考える。

まず、学習データについて各分類器の、各クラスの確率が出力される前の全結合層から特徴量を抽出する。この時、各画像の特徴量の次元はそれぞれ 1024 である。抽出した特徴量に対して、特徴量選択手法 Boruta[3]を用いて、分類に有効な特徴量を選択する。この手法では、判別に関与しない偽の特徴量を生成し、真の特徴量と偽の特徴量を合わせたものに、Random Forest を用いて重要度を比較することで、真に重要な特徴量のみを抽出する。ここでは、3 種類の分類器から抽出した重要な特徴量を統合することで新しい分類器を作成する。

6. 検証

6.1 データセット

CNN によってエルボ、フランジ、ストレートのパイプ、T 字型のパイプ、バルブ、圧力計の 6 種類のクラスに分類した。データセットの一部を図 6 に、データセットの枚数を表 1 に示す。データセットの 1/2 をテスト用データとして使用した。

表1 各部材のデータセット数

Elbow	Flange	Straight	T	Bulb	Manometer
171	161	80	21	43	7

6.2 検証結果

各部材に対する正解率、F 値をそれぞれ表 2、3 にまとめた。RGB や Intensity 画像の分類器と比べ、Depth 画像の分類器が全体として精度が良くなった。また、CAD モデルを使った分類器は使わなかった分類器と比べ精度が向上し、データ数

が少なかったティ、バルブ、圧力計に関して特に精度が向上した。また、Random Forest を用いた分類器は今回行った検証の中で一番精度の良い分類器となった。CAD モデルを使った分類器の精度が改善したことから、標準部材の 3D モデルによるデータの拡張が有効な手法であるということがわかる。また、2 次元特徴量と 3 次元特徴量の統合も精度向上の有効な手段である。

表2 検証結果 (正解率)

	RGB	Intensity	Depth	Depth & CAD	RF
Elbow	0.929	0.924	0.954	0.941	0.975
Flange	0.945	0.933	0.954	0.954	0.975
Straight	0.979	0.983	0.975	0.983	0.987
T	0.941	0.962	0.966	0.971	0.979
Bulb	0.992	0.975	0.966	0.979	0.992
Manometer	0.800	0.996	0.979	0.987	1.000

表3 検証結果 (F 値)

	RGB	Intensity	Depth	Depth & CAD	RF
Elbow	0.898	0.898	0.938	0.920	0.965
Flange	0.918	0.899	0.930	0.929	0.963
Straight	0.935	0.950	0.921	0.951	0.962
T	0.500	0.400	0.556	0.667	0.737
Bulb	0.950	0.857	0.818	0.865	0.950
Manometer	0.800	0.800	0.750	0.857	1.000

7. 結言

点群から作成した透視投影画像を用いて 6 種類の部材の分類を行った結果、十分な精度で分類可能であること、データ数の少ない部材に対しても、データを拡張することで精度が向上することがわかった。また、2 次元特徴量と 3 次元特徴量の統合により、分類の精度が向上することがわかった。

なお、点群を用いた物体認識では、非構造点群を用いた手法も知られている。今後は、そうした手法との比較を行うとともに、非構造点群の特徴量を融合することで、認識精度をさらに向上させることが可能かどうかを検討していきたい。

参考文献

- [1] 松岡 諒, 増田 宏, 大規模点群からの生産設備の形状再構成(第 1 報), 精密工学会論文誌, 80(6), 604-608, 2014
- [2] 重田航平, 江藤信輔, 和田太一, 増田 宏: 工業設備の大規模点群からの部材形状の抽出と認識, 精密工学会秋季講演会, 2019
- [3] Kursa M., Rudnicki W., "Feature Selection with the Boruta Package" Journal of Statistical Software, Vol.36, Issue 11, 2010