

工業設備の大規模点群からの部材形状の抽出と認識(第3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)で取得した高密度点群を用いた3D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、工業設備内は装置や部材、配管系統が複雑に入り組んでいる。そのため、スキャナの設置可能箇所が限定される、オクルージョンが発生する、点密度や計測精度が不十分な領域ができるといった問題が発生する。この条件で検出できる曲面は平面や円柱、回転体など、比較的参数が簡単なものに限定されてしまう。

我々はこれまでに、検出した曲面同士の組み合わせから配管同士の間に存在する部材を推定するという手法を開発している[1]。しかし、曲面同士の組み合わせから検出することができる部材は限定的で、汎用性が高くない、配管が複雑に入り組んでいる場所では組み合わせの解が複数存在し、誤認識を起こしてしまうという問題があった。

前報では、点群を2次元平面に投影し、部材の画像を作成することで、2次元CNNを適用し、部材を識別する識別器を作成した。また、各識別器から抽出した特徴量を統合することで識別精度が向上することを確認した。しかし、点群を2次元平面に投影することで点群の3次元情報が消失してしまうという問題点があった。近年では、点群を直接入力として利用する3次元CNNの研究が進んでいる。そこで、本報では、3次元CNNとして有名なPointNet++を利用した部材の識別が行えるかを検討する。また、前報で作成した2次元CNNの特徴量とPointNet++から抽出できる3次元CNNの特徴量を利用して識別精度が向上するかを検討する。

2. 手法の概要

本研究では、TLSにより計測した高密度点群及び、点群から作成した画像を用いた、深層学習による工場内の部材認識を考える。本研究で使用する点群は、RGBカラー、レーザ反射強度、スキャナからの距離を属性として保持している。

まず、前報[2]と同様に点群から透視投影画像を作成する。スキャナで計測した点群は球面座標系に変換できるため、天頂角 θ と方位角 ϕ を軸とした2次元平面上に各点を投影することで2次元画像を作成することができる。しかし、球面上の分布を平面に引き伸ばしているため画像の端で歪みが生じ、直線性が保存されない。そこで、図1のように仮想的な透視投影平面に各点を投影することで、透視投影画像を作成する。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。

透視投影画像の各画素に与える数値によって、RGB、Intensity、Depth画像の3種類の画像を作成できる。この3種類の透視投影画像と点群をCNNに適用して、各データの特徴量ベクトルに変換し、部材の同定を行う。また、2次元CNNと3次元CNNから特徴量を抽出し、それらを統合することで分類精度が向上するかを検証する。

3. データ作成

3.1 RGB, Intensity, Depth画像の作成

RGBカラーは0以上255以下の3つの数字[R,G,B]の組み合わせで表現される。しかし、CNNの入力には収束性を考慮して、0~1の値を与えることが望ましいため、各RGBカラーの値を0~1に正規化する。レーザ反射強度は、スキャナにより照射されたレーザの反射光の強さで、機種に応じ異なるオーダの解像度を持つ。本研究では、0~1に正規化する。これらの数値を各画素に与えることで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しているため、点群の座標を各画素に割り当てることができる。そのため、画像上で隣接する点同士の距離を調べることで、連続した点のみを抽出することができる。ここでは、部材のみが写っている画像を作成するため、図2のように連続な面のみを抽出し、背景を消去している。

スキャナからの距離は、点群全体と比較すると同一部材間での距離差が少ない。そのため、画像にしたい対象の部材のみに注目する。背景を消去した状態で各点のスキャナ原点からの距離を0~1に正規化することで、距離差をよく反映したDepth画像を作成する。

3.2 点群データ作成

PointNet++は構造化されていない点群を入力とする3次元CNNである。先程と同様に、部材のみの点群を抽出して各点の座標値を保存することで、PointNet++の入力とする。

4. データの拡張

4.1 画像処理を用いたデータ拡張

実測データから取得できる部材だけではデータ数が不十分で、過学習を起こす可能性が高い。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。元の画像に対して、回転、拡大縮小、輝度値変更、ノイズ付加、反転の処理を施し、1枚の画像から新たに14枚の画像を作成する。

4.2 CADモデルを用いたデータ拡張

Depth画像と点群データは各点の座標値のみを用いて作成することができる。よって実測された点群データではなく、自作したCADモデルを用いてDepth画像と点群データ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則ったモデルを作成する。一方、バルブのように主要寸法以外規定されていない部材や、フランジのように形状が多様な部材が存在する。その場合には、実測データで確認された形状に則って3Dモデルを作成する。

3Dモデルに密な点を生成することで新しい点群データを取得することができる。しかし、計測データではスキャナ原点から見て部材の裏側は点を取得できない。そのため、CADデータから生成する点も設定した原点から見える点のみを採用する。1つの3Dモデルについて、その位置姿勢を様々なに変化させることで、多数の点群データを作成することができる。Depth画像は図3のように作成した点群データを透視投影平面に投影することで作成することができる。

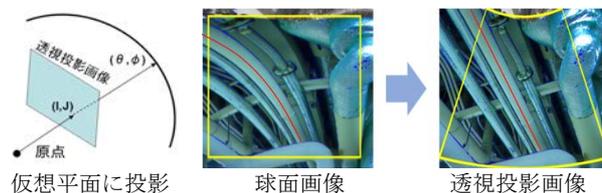


図1. 透視投影画像への変換

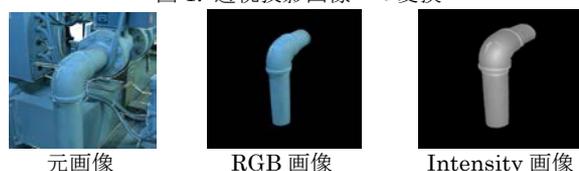


図2. 背景を消去した画像

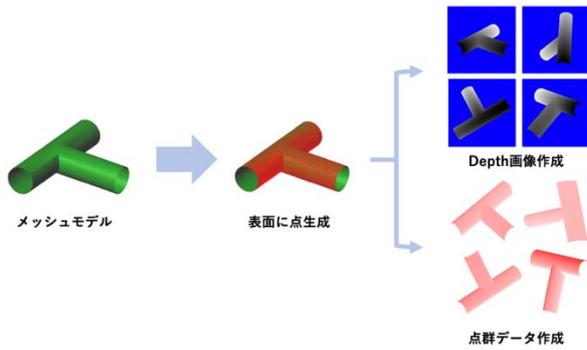


図 3. CAD データからのデータ拡張

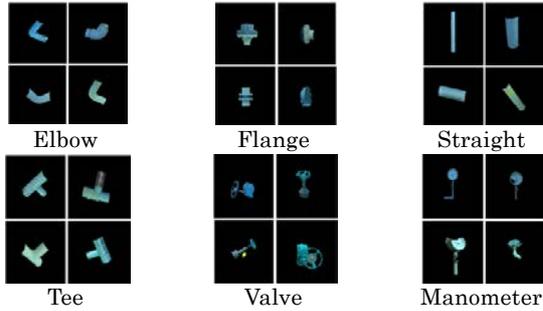


図 4. データセット

5. 深層学習による分類

5.1 深層学習による部材の同定

本研究では、2次元 CNN として、ImageNet による学習済みの VGG16 モデルの上層を利用する。3 種類の画像について finetuning を行うことで 3 種類の識別器を作成する。3 次元 CNN では、ImageNet のように finetuning に有効な汎用的ビッグデータは提供されていない。そこで、PointNet++ を直接利用する識別器と、PointNet++ のベンチマーク用データとして使われていた、ModelNet40[4]を用いて finetuning を行う識別器の 2 種類の識別器を作成し精度の比較を行う。

5.2 特徴量統合

前報では 3 種類の画像についての識別器から出力される特徴量を統合することで認識率が向上することを確認した。本報では、画像から作成した識別器に加えて PointNet++ によって作成した識別器の特徴量も用いて、どの特徴量の組み合わせが識別に有効か検証する。統合した特徴量は全結合層と Random forest にそれぞれ入力して識別結果を出力する。

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、ティー、バルブ、圧力計の 6 種類のクラスに分類した。データセットの例を図 4 に、データ数を表 1 に示す。データセットの 1/2 をテストデータとして使用した。

表 1. 各部材のデータ数

Elbow	Flange	Straight	Tee	Valve	Manometer
171	161	80	21	42	7

6.2 単一の特徴量を使用した識別器の比較

単一の特徴量で作成した識別器について、各部材に対する F 値とその平均を表 2 に示す。画像から作成した識別器については、RGB 画像と Intensity 画像の識別器と比べ、Depth 画像の識別器が全体として精度が良かった。これにより、CAD モデルによるデータの拡張によって識別器の汎化性能が向上したことがわかる。また、点群から作成した識別器について、ModelNet40 を使って finetuning を行った識別器よりも、finetuning を行わなかった識別器の方が精度は良かった。これは、ModelNet40 が室内にある家具などを中心に作成されているため、工業設備内の部材識別における事前学習には適していなかったからだと考察できる。

6.3 特徴量統合についての比較

特徴量を統合して作成した識別器について、各部材に対する F 値とその平均を表 3,4 に示す。このとき、PointNet++ の特徴量は、表 2 で精度が良かった finetuning なしの結果を利用している。表 3 は特徴量を全結合層に入力した結果、表 4 は特徴量を Random forest に入力した結果である。

全体として全結合層に入力した結果の方が Random forest に入力した結果よりも良くなった。特に、3 種類の画像の特徴量と、点群の特徴量を統合した識別器が、本報で作成した中で一番精度の良い識別器になった。

表 2. 単一の特徴量での識別結果

	RGB	Intensity	Depth	PointNet++	PointNet++ (finetuning)
Elbow	89.9	89.8	92.0	81.6	76.1
Flange	91.8	89.9	92.9	89.8	85.2
Straight	93.5	95.0	95.1	92.1	77.6
Tee	50.0	40.0	66.7	66.7	41.4
Valve	95.0	85.7	86.5	52.9	36.8
Manometer	80.0	80.0	85.7	20.7	33.3
Average	89.8	88.1	91.2	82.3	74.1

表 3. 特徴量統合結果 (全結合層に入力)

	Depth+ RGB+ Intensity	Intensity+ RGB+ PointNet++	Depth+RGB+ Intensity+ PointNet++
Elbow	94.4	92.7	96.6
Flange	96.1	92.5	98.8
Straight	97.4	96.2	97.4
Tee	63.2	46.2	88.9
Valve	95.2	95.0	100
Manometer	100	80.0	100
Average	94.3	91.3	97.5

表 4. 特徴量統合結果 (Random forest に入力)

	Depth+ RGB+ Intensity	Intensity+ RGB+ PointNet++	Depth+RGB+ Intensity+ PointNet++
Elbow	93.7	93.7	93.2
Flange	95.1	96.9	95.7
Straight	97.4	95.0	96.2
Tee	62.5	53.3	53.3
Valve	90.0	95.0	94.7
Manometer	80.0	80.0	80.0
Average	93.0	93.2	92.8

7. 結言

点群から作成した透視投影画像を用いた識別器と、点群を用いた識別器から取得した特徴量を統合し、全結合層に入力した結果、十分な精度で分類できる識別器を作成することができた。また、PointNet++ について ModelNet40 を用いた finetuning は部材の分類には適さないことがわかった。

しかし、本報で行った検証ではテストデータが十分ではない。今後は、識別器を作成する際、訓練データに実測データを利用せず、CAD データのみを使用するなどして、テストデータを十分に確保する手法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] Charles R. Qi, Li Yi Hao, Su Leonidas, J. Guibas: PointNet++: Deep Hierarchical Feature Learning on Points Sets in a Metric Space NIPS, 2017
- [4] Z. Wu, S. Song, A. Khosla, F. Yu, L. Zhang, X. Tang, and J. Xiao: 3d shapenets: A deep representation for volumetric shapes. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pages 1912-1920, 2015.