

工業設備の点群から部材認識における学習データの検討

電気通信大学 ○花井 大輝, 重田 航平, 増田 宏

1. 緒言

近年, 固定式レーザスキャナ(TLS)を用いて, 工業設備の詳細な点群データが得られるようになった. こうした点群には様々な物体が含まれているため, 点群データの活用には, 必要となる対象物を抽出することが必要になる. 我々は, これまでの研究で, 深層学習を用いて, 工業設備の大規模点群から, 配管系統の部材を認識する手法を示した[1].

一般に, 深層学習には, 大量の学習データを必要とする. 点群データについては, 研究目的で共通に用いられるデータセットがいくつか知られているものの, 配管系統の点群が含まれておらず, 部材認識には利用できない. そのため, 大量の配管系統の学習データを作成する必要があるが, 工業設備の点群を大量に用意することは難しく, しかも, 大量のラベル付き点群を得るには, 多大な労力を必要とする. 少数の CAD データから大量の学習データを自動作成することができれば, この問題を解決できることが期待できるが, 我々の評価実験では, CAD モデルから自動生成した点群を学習データとして用いると, 実測点群を用いた場合に比べて, 識別性能が大幅に低下することがわかった.

そこで本研究では, CAD モデルから作成した Depth 画像によって学習された識別器によって, 高い識別率を達成する方法について検討する.

2. 点群から生成されたデプス画像による物体認識

2.1 CAD からの点群の生成

図 1 に, CAD モデルからの点群生成を示す. 本手法では, CAD モデルを X, Y, Z 軸の周りにランダムに回転し, 仮想的にレーザスキャナを照射して点群を生成する. この操作を多数繰り返すことで, 学習用の点群データを生成する. 図 2 に, 配管, エルボ, バルブ, ティー, フランジ, 圧力計の CAD モデルを示す. ここでは, これらの CAD モデルを用いて, 学習用データを作成する.



図 1. CAD モデルからの点群の生成



図 2. 配管系統の CAD モデル

2.2 深層学習による部材認識

本研究では, 点群からデプス画像を生成し, 画像認識のための深層学習モデルである VGG16 を用いて部材認識を行う. VGG16 は ImageNet を用いて学習済みとし, Fine Tuning によって学習を行う. デプス画像は, 図 3 のように, 点群をレーザ照射方向に投影して作成する. また, デプスは, 0 以上 1 以下に正規化する.

ここでは, CAD から作成した点群を学習データとして学習させた後, 実際の工業設備を計測して得られた点群をテストデータに用いて評価を行う. 評価は, エルボ, フランジ, ストレートのパイプ, T 字のパイプ, バルブ, 圧力計の 6 種類のクラスに分類して行う. テストデータの個数を表 1 に示す. また, CAD から生成す

る学習用データは, 各部材に 80 個生成し, 回転, 反転, 輝度変更, 拡大, 縮小の画像処理によるデータ拡張を施し, 14 倍に拡張する.

2.3 CAD データと実データによる認識性能の比較

次に, 学習データとして, CAD から生成された点群を用いた場合と, 実測点群から手動で抽出した点群を用いた場合について, 認識性能を比較した. 結果を表 2 に示す. 明らかに, CAD を学習データとして用いた場合には, 認識率が大幅に低下している. このことから, CAD から生成された点群が, 現実の点群データの特徴を十分に反映できていないと考えられる.

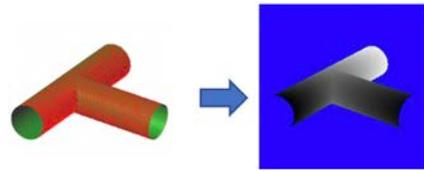


図 3 点群からのデプス画像の生成

表 1 テストデータの個数

Straight	Elbow	Flange	Tee	Valve	Manometer
80	171	161	21	41	7

表 2 学習データによる部材認識の F 値の違い

	実測点群のみ	CAD のみ
Flange	95.5	78.7
Elbow	90.8	73.5
Straight	92.5	88.9
Tee	66.7	52.9
Valve	97.6	86.1
Manometer	100	83.3
(Average)	(90.5)	(75.4)

3. 学習データへのノイズ付加

CAD から生成した学習データは, 実データのようなノイズや欠落がないことが, 認識率低下の原因であると考えられる. そこで, ノイズと欠落を追加して認識率が改善するかどうかを検討する.

3.1 実測値に基づくノイズの付加

ここでは, 実測点群からノイズの大きさを算出し, CAD から生成された点群にノイズとして付加する. 配管は円柱から構成されているため, 図 4 に示すように, 配管の点群に円柱をフィッティングすることによって, 実測点群のノイズの大きさを推定できる. ここでは, 配管の点群を用いて, レーザ照射方向の残差の標準偏差を算出する. CAD から生成される点群へのノイズの大きさは, 正規分布に従う乱数に, 算出された標準偏差を乗じたものとする.

なお, ノイズレベルは, レーザと曲面法線との角度に依存する. そこで, 照射角度ごとに異なるノイズレベルとする場合と, 照射角度を考慮しない場合に関して, 認識率を比較する.

3.2 評価実験

CAD から生成される点群に対して, 2 通りの方法でノイズを付加した Depth 画像を作成し, 学習データとして用いた. 一方の Depth 画像では, レーザ照射角度と曲面の法線の成す角度を 10 度毎に離散化し, それぞれの範囲の残差の標準偏差を計算し, 角度に応じたノイズを与えた. もう一つは, 角度を考慮せずに計算した残差の標準偏差を用いてノイズを生成した.

表 3 に結果を示す。この評価においては、レーザ照射角度を考慮しても、認識率は改善しなかった。また、ノイズを与えない場合よりも認識率はむしろ低下しており、改善は見られなかった。



図 4 CAD から生成される点群へのノイズ付加

表 3 ノイズ付加した場合の認識結果 (F 値)

	角度を考慮	角度考慮なし	ノイズなし
Flange	73.9	75.0	78.7
Elbow	68.6	66.2	73.5
Straight	80.6	82.6	88.9
Tee	54.5	55.0	52.9
Valve	79.4	77.8	86.1
Manometer	83.3	83.3	83.3
(Average)	(73.4)	(73.4)	(75.4)

4. 点群の欠落を考慮した学習データ

4.1 一部が欠落した点群の生成

次に、点群の一部が欠落した学習データを作成する。ここでは、CAD から点群を生成した後、一つの点群をランダムに選択し、選択した点群の k 近傍を除外する。近傍数の k には、最小値と最大値を与えて一様乱数によって個数を決める。この操作によって、一つの穴が生成される。また、操作を繰り返すことにより、複数個の穴が欠落した点群が生成される。

ここでは、穴の大きさ (近傍数 k) と穴の個数を変えて学習データを生成し、認識率への影響を調べる。

4.2 欠落部分の大きさ (近傍数)

まず、欠落させる穴の個数を 3 に固定し、穴の大きさを変えて、認識率を調べた。ここでは、近傍数の最小値と最大値を、点群数の比率として、表 4 の 3 通りで評価する。図 5 に点群の例を示す。

評価結果を表 5 に示す。この評価では、ケース 1 の近傍数が最も認識率が高く、欠落がない場合よりも向上した。

表 4 点群欠落の近傍数

	最小近傍数	最大近傍数
ケース 1	1 %	3 %
ケース 2	3 %	9 %
ケース 3	9 %	15 %



図 5 3 通りの近傍数 (左からケース 1, 2, 3)

表 5 異なる近傍数での認識結果 (F 値)

	ケース 1	ケース 2	ケース 3
Flange	84.4	84.1	83.4
Elbow	84.6	81.8	78.6
Straight	86.7	81.8	79.7
Tee	58.1	62.5	37.0
Valve	81.7	70.8	68.8
Manometer	75.0	85.7	76.9
(Average)	(78.5)	(77.7)	(70.7)

4.3 欠落部の個数

次に、ケース 1 の近傍数を用いて、穴の個数を 3, 6, 12, 24, 36 とした学習データで評価を行った。図 6 に点群の例を示す。

評価結果を表 6 に示す。この評価では、穴の個数が 3 個の場合が最も認識率が高かった。

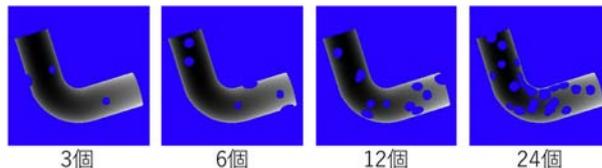


図 6 欠落部の個数が異なる点群の例

表 6 点群の欠落数

	3 個	6 個	12 個	24 個	36 個
Flange	84.8	85.5	90.2	86.8	92.2
Elbow	84.6	82.4	86.8	81.4	79.6
Straight	86.7	81.8	85.1	86.1	66.7
Tee	58.1	64.7	85.4	63.4	43.3
Valve	81.7	76.5	62.3	62.3	32.6
Manometer	75.0	54.4	58.5	46.1	40.0
(Average)	(78.5)	(74.2)	(74.8)	(71.0)	(59.1)

4.4 学習データの個数の影響

CAD データからの点群生成では、任意の個数の学習データを作成することが可能である。そこで、ケース 1 の近傍数で、欠落数を 3 とした場合において、データ数を 2 倍、3 倍、5 倍、8 倍に増加させて学習を行った。

評価結果を表 7 に示す。評価の結果、データ数を増大させることによって、認識率は若干向上した。

表 7 データ数拡張

	1 倍	2 倍	3 倍	5 倍	8 倍
Flange	84.8	87.3	85.4	87.8	82.4
Elbow	84.6	85.4	83.4	84.9	78.4
Straight	86.7	84.1	82.4	83.5	83.2
Tee	58.1	70.3	64.9	71.8	71.8
Valve	81.7	69.7	75.4	80.6	74.6
Manometer	75.0	70.6	85.7	80.0	85.7
(Average)	(78.5)	(77.9)	(79.5)	(81.4)	(79.4)

5. 考察

本研究における評価実験では、CAD から生成した点群を学習データに用いる場合、ノイズ付加は認識率の向上に寄与しなかったが、部分的に欠落した点群は、認識率の向上に寄与することがわかった。また、学習データの個数を増大させることも効果的であった。一方で、CAD から生成した点群による認識率は約 80% であり、実点群を用いて学習した場合の 90% (表 2) には、まだ大きく及ばない結果となった。

本研究においては、ノイズと欠落に関して評価を行なったが、実データにおいては、これ以外の要因による特徴量を学習している可能性がある。また、点群の欠落として、ランダムに円の穴を生成したが、欠落のさせ方については、境界部分を優先的に欠落させるなどの方法考えられる。

6. 結言

本研究では、CAD モデルから生成した点群を学習データとして用いて、TLS で得られた実測点群の部材認識を行う方法について検討した。ノイズ付加においては、実計測点群から算出したノイズを付与する方法を示し、点群の欠落においては、ランダムに円領域を除去する方法を示した。評価実験の結果、ノイズ付加は効果がなかったが、点群を欠落させる方法は効果的であった。しかしながら、実測点群による学習データによる認識率とは、まだ大きな差があるため、今後は、より実計測点群に近い点の欠落の方法を検討する必要がある。

参考文献

[1] 重田 航平, 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 (第 2 報), 精密工学会春季講演会, 2020