

# 点群の深層学習のための CAD モデルからの学習データ生成 Generating Training Data from CAD Models in Deep Learning for Point Clouds

電気通信大学 ○南雲 拓真, 花井 大輝, 重田 航平, 増田 宏

## 1. 緒言

地上型レーザースキャナ(TLS)を用いることで、大規模な設備などにおいても点群データを取得することができる。近年では、こうした大規模な点群データにおいて部材の認識などを行うために、深層学習を用いる手法が提案されている。点群の深層学習には、一般的に大量のラベルつき点群データが必要となるが、こうしたデータを作成するには多大なる労力が必要とされる。よって実際に工業設備などにおいては実計測データが不足しているため、深層学習を行うことが困難である。

こうした問題を解決するためには、CAD モデルから点群を生成し深層学習の訓練データとして利用する手法が有効である。しかし、[1]の研究により、CAD モデルから生成した点群を訓練データとして用いて学習を行うと、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分かっている。また[1]では、CAD モデルから一部が欠落した点群を生成する手法が提案されているが、この手法では、欠落がないデータに比べて識別性能は向上したものの、まだ実測点群には及ばないことが分かっている。

そこで本研究では、実計測データから生成したデプス画像を用いた学習において、CAD モデルから生成したデプス画像を訓練データとして追加することで、より良い精度で部材を識別する方法について検討する。

## 2. デプス画像を用いた深層学習による部材分類

### 2.1 使用するモデル及び生成方法

本手法では、X, Y, Z 軸上で CAD モデルを回転及び並進させ、仮想的なレーザースキャナから点群を生成する。この回転角度と並進の距離をランダムに決定し、この操作を繰り返すことで、訓練データを取得する。図 1 に部材認識に用いる部材を示した。部材はエルボ、フランジ、ストレート、ティ、バルブ、圧力計である。

### 2.2 CAD モデルからの点群の生成

仮想的なレーザースキャナから点群を生成する方法として、メッシュ上の三角形の面積に応じて点数を変更する手法を用いる。CAD モデルの表面は三角形によって構成されている。点を生成する三角形は、図 2 のように仮想的なスキャナの原点に向いている面の中から選択される。この三角形上に、0 から 1 の間の均一な乱数  $\alpha$ ,  $\beta$  と三つの頂点 A, B, C を用いた式 (1) に表される座標の点を生成する。実際のデプス画像の生成の様子については、図 3 に示した。



図 1. 部材認識に用いる部材

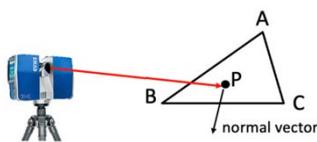


図 2. 仮想的なスキャナからの点の生成 [2]

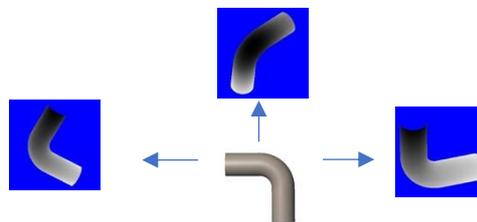


図 3. CAD モデルからの訓練データ生成

$$P = (1 - \sqrt{\alpha})A + \sqrt{\alpha}(1 - \beta)B + \sqrt{\alpha}\beta C \quad (1)$$

### 2.3 深層学習による部材の分類

本手法では学習の精度を高めるため、学習済みモデルとして VGG16 をモデルに組み込み、学習を行う。入力は、点群をスキャナ原点方向に投影したデプス画像を用いる。デプスは、0 以上 1 以下に正規化する。

実計測データとして、工業設備を計測して得られた点群を用いる。実計測データを二等分し、それぞれ訓練データとテストデータとする。また、訓練データを拡張するため、CAD モデルから生成した点群を追加した。訓練データ及びテストデータの個数は表 1 と表 2 に示した。これらの訓練データを用いて学習を行ったのち、テストデータを用いて評価を行う。

## 3. 点群データの曲面再構成

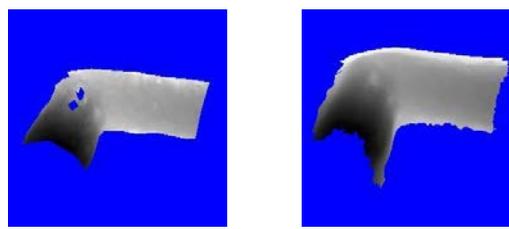
点群からデプス画像を生成する際、点群からメッシュを作成している。本手法では、実測点群が持つ特有のノイズを除くため、点群データの曲面再構成と点のリサンプリングを行い、部材認識の識別性能が向上するかどうかを検討する。

### 3.1 Poisson Surface Reconstruction

点群に対してメッシュを生成して汎用局面を生成する手法の一つに、Poisson Surface Reconstruction (PSR) [3]がある。この手法は、法線が算出された点群に対し、閉曲面を生成することで汎用局面を生成する方法である。実際に生成される局面から生成されたデプス画像を図 4 に示す。この手法は欠落のない点群を前提としているため、点群に欠損があった場合誤った形状の局面を生成してしまうことがある。

### 3.2 CAD データへの誤生成形状の付加

本手法では、図 5 右のように部材の淵に生成される尖ったきざみ目のような形状に対応するため、CAD データにも同様の形状を付加することでより精度の高い認識を目指す。CAD データへのノイズ付加は、デプス画像の生成時に行う。生成されるデプス画像のエッジを検知し、一定の確率で三角形の形状を付加する。



PSR 前のデプス画像

PSR 後のデプス画像

図 4. PSR による形状再構成

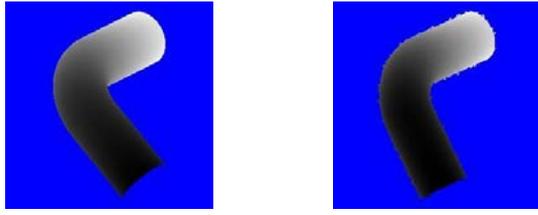


図5. 三角形形状の付加

#### 4. 評価実験

##### 4.1 PSR の評価実験

学習データとして、CAD モデルから生成したデプス画像と実計測点群から生成したデプス画像を用いて、2種類のクラスに分類するモデルを作成した。このモデルを用いて、

- (a) 実計測点群から生成したデプス画像とCADモデルから生成したデプス画像の分類
- (b) PSRを施した実計測点群から生成したデプス画像とCADモデルから生成したデプス画像の分類

の二つの分類を行い、PSRによって識別器を騙すことが可能かどうかについて検証した。データ数は以下の表1に示した。

表2に結果を示す。この結果を見ると、PSRを施した点群ではF値が下がっている。また、実測点群のみの正解率では、PSRを施した点群の正解率が元の点群に比べて低くなっている。以上のことから、識別器がPSRを施した点群をCADから生成した点群と誤って認識していた。

##### 4.2 部材の分類

評価はT字の配管、ストレートの配管、エルボ、バルブ、ティー、フランジ、圧力計の6種類のクラスに分類して行う。また、訓練データはデータ拡張としてスケール、回転、高さ、幅、照度の変更による画像の処理を行う。これにより、データ数を15倍に拡張して学習を行った。データ数は表3と表4に示した。また、データ拡張の例を図6に示した。

また、ここではCADモデルから生成される点群に微小な三角形の形状を付加したデプス画像を作成し、実計測点群データから作成したデプス画像とともに訓練データとして用いて、学習を行った。また、このとき形状を付加する確率を50%、80%、90%と変化させ、認識率が改善されるかどうかについて検証を行った。最後に、CADから生成した点群と形状再構成をしていない点群で認識率を比較した。

表5に結果を示す。この結果を見ると、付加確率80%付近では形状再構成をしていない点群に比べて認識率が向上していることがわかる。しかし、それ以外の付加確率では結果の改善は見られなかった。

表1. 訓練データと学習データの個数

	訓練データ	テストデータ (a)	テストデータ (b)
CAD	239.0	244.0	244.0
実計測	239.0	244.0	244.0

表2. 評価実験の結果

	F値	実測点群のaccuracy(%)
テストデータ (a)	83.6	64.8
テストデータ (b)	78.9	50.8

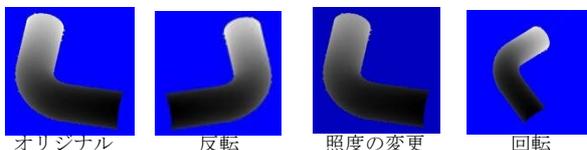


図6. データ拡張の例

表3 訓練データの個数

	Elbow	Flange	Manometer	Straight	Tee	Valve
実測点群	86	81	4	40	11	22
CAD点群	80	120	80	80	80	80
合計	166	201	84	120	91	102

表4 テストデータの個数

Elbow	Flange	Manometer	Straight	Tee	Valve
85	80	3	40	10	19

表5. 三角形の形状を付加した場合の分類結果(F値)

	20%	50%	80%	90%	PSRなし
Elbow	60.2	49.6	88.3	84.3	88.6
Flange	75.8	69.3	90.8	88.5	91.7
Manometer	80.0	57.1	75.0	50.0	50.0
Straight	84.5	0.0	84.9	84.1	87.3
Tee	30.8	84.1	75.0	0.0	33.3
Valve	84.4	85.0	90.9	82.4	87.5
重みつき平均	70.6	52.2	88.1	81.6	86.5

#### 5. 考察

本研究における評価実験では、最初の検証によって、PSRによって実測点群とCADモデルから生成した点群の識別器を騙すことができることがわかった。一方で、PSRを利用した部材の分類では、最初の検証ほど実測点群との差が見られなかった。しかし、分類の結果を見ると、データ数が多いエルボ、フランジ、ストレートの配管ではわずかに及ばないものの、データ数の少ないマノメータ、T字の配管、バルブでは、いずれも実測よりも高いF値になっていることから、学習データの少ない部材についても安定した結果が出せるようになってきていると言える。

以上の識別結果をさらに向上させ、より簡便な方法で処理するため、PSRの処理によって生まれる部材の淵に生成される尖ったきざみ目のような形状の処理の方法を改善する必要がある。今回はCADモデルから生成した点群を処理することでこの問題に対処した。しかし、作業をより単純化するため、直接縁を平滑化することで、CADモデルから生成した点群により近いデータにする方法を検討する必要がある。

#### 6. 結言

本研究における検証では、[1]のように全ての訓練データをCADモデルから生成する方法ではなく、少数の実計測点群データで構成された訓練用のデータセットを拡張する方法について検討した。PSRはノイズの多い実計測データを平滑化するために効果的な手法であったが、余分な形状が生成してしまうという問題点があった。今後は、全ての訓練データをCADデータから生成した点群データに置き換える手法や、PSRの他に点群の平滑化に有効な手法について検討する。

#### 参考文献

- [1] 花井 大輝, 重田 航平, 増田 宏: 点群を用いた工業設備の部材認識における学習データに関する検討, 精密工学会春季講演会, 2021
- [2] Shigeta, K; Masuda, H: Data Augmentation of Classifiers for Components in Industrial Plants Using CAD Models, Computer-Aided Design & Applications, 2021
- [3] M. Kazhdan, M. Bolitho, H. Hoppe, Poisson surface reconstruction, In Proceedings of the symposium on Geometry Processing, 61-70, 2006