

## 深層学習による点群の特徴量抽出手法を応用した構造的情報の推定手法の検討

日本工営株式会社 正会員 ○辻井 純平 中野 雅章 合田 哲朗

### 1. はじめに

LiDAR 技術や SfM 技術の発展、普及により、土木構造物の現場で3次元の点群データが取得される場面が増えつつある。また、点群データに対する解析手法として深層学習の活用が進められており、汎用的な深層学習モデルとして分類やセグメンテーションをタスクとしたものが提案<sup>1)</sup>されている。こうしたモデルは任意のデータセットを用いて土木構造物にも適用可能である。しかし、分類やセグメンテーションタスクの出力は点群全体や各点のラベルであり、維持管理の中での直接的な活用には至っていない。現場で取得されたデータを end-to-end に活用するためには、深層学習のタスクを回帰問題に応用し、より直接的に活用可能な情報を抽出することが必要である。

### 2. 維持管理への活用に期待される構造的情報

土木構造物として橋梁を対象とした場合、**図1**のように点群の座標軸において橋軸方向がどの方向であるかは有用な情報となりうる。点群データを手動で操作する際は橋軸方向を基準に行うことが多く、橋軸方向が既知であることは操作性に大きく影響する。また、自動モデリングなどの自動処理を試みる場合<sup>2)</sup>も橋軸方向が基準となるため、これが既知であることは処理精度に大きく影響すると考えられる。このように手動処理、自動処理のいずれにおいても橋軸方向を精度良く推定することは有用である。

橋軸方向の推定には主成分分析による方法もあるが、現場によって取得範囲が限られることや欠損を含むことで不完全な点群となることも多く、十分な推定

精度が得られないと考えられる。深層学習ではこのような場合も頑強性を有した推定が可能と考えられる。

本稿では活用が期待できる構造的情報として橋軸方向の推定を目的とし、深層学習により橋軸方向のベクトルを予測する回帰モデルを構築した。

### 3. 使用するデータセットとサブサンプリング

データセットには Lu<sup>3)</sup> が CC-BY-4.0 ライセンスで公開するものを用いる。これは RC 橋梁 10 橋に対する実測のデータで、橋梁全体が高密度の点群で構成されている。ここでは平面線形が直線の 8 橋を使用した。これらに対し手動操作から橋軸方向のベクトル成分を算出し真値のベクトルとした。また、データセットの数は限られているため、サブサンプリングによりデータセットの拡充を行う。ここでは、前述した点群の不完全性を考慮し、頑強性を確保するため下記および**図2**に示す手順によりサブサンプリングを行う。

- (1) 点群  $P$  に対してボクセルダウンサンプリングを行い、処理後の点群を  $P_{voxel}$  とする。
- (2)  $P_{voxel}$  の中からサンプリングの基準点となる 1 点  $p_i \in P_{voxel}$  を選択する。
- (3)  $p_i$  と各点  $p_j \in P_{voxel}$  との距離  $d_{ij} = |p_j - p_i|$  を算出する。
- (4) Softmax 関数により距離  $d_{ij}$  を重み  $w_j$  に変換する。ここで、 $a$  は抽出範囲に関するパラメータであり、 $a > 0$  の範囲で小さいほど基準点から遠い点もサンプリングされやすくなる。

$$w_j = \frac{\exp(-a \cdot d_{ij})}{\sum_k \exp(-a \cdot d_{ik})}$$



図1 点群データの座標軸と橋軸方向




図2 サブサンプリング処理の模式図

キーワード 橋梁, 維持管理, 点群, 3次元データ, 深層学習, 回帰モデル

連絡先

〒300-1259 茨城県つくば市稲荷原 2304 日本工営株式会社 中央研究所 TEL: 029-871-2040

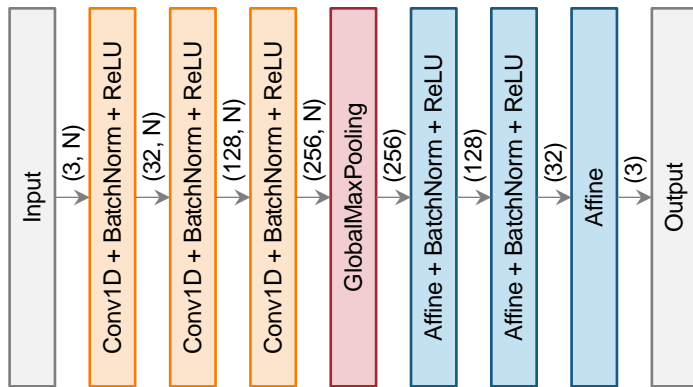


図3 深層学習モデル(括弧は入出力サイズ)

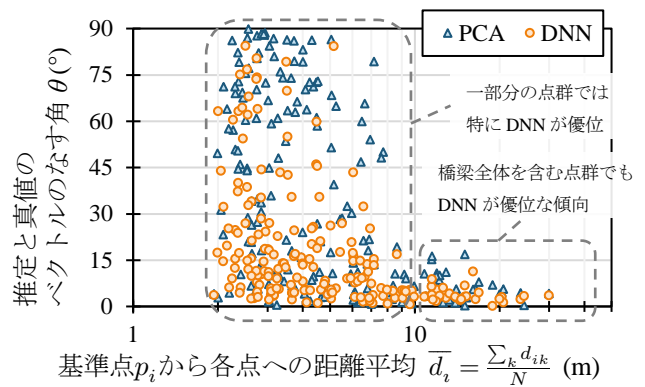


図4 橋軸方向の推定結果

(5)  $w_j$ を重みとした重み付き確率で  $N$  点のサンプリングを行い、処理後の点群を  $P_{sampled}$  とする。

この手順において、基準点および範囲について多様なパターンを考慮するため、(2)の  $p_i$  の選択および(4)の  $a$  の設定には乱数を用いて複数回のサブサンプリングを行った。また、学習の際には正規化処理として点群の座標平均が座標中心となるように、かつ主成分分析による第一主成分方向が  $X$  軸となるように座標値の線形変換を行っている。併せて、中心から最遠点までの距離が 1 となるようスケールリングも行っている。

#### 4. 橋軸方向を推定するモデルの構築と学習

本稿で用いた深層学習モデルを図3に示す。図中で括弧に示すのは点群 1 データあたりの入出力サイズであり、XYZ 座標に対応する 3 チャンネル、点数  $N$  のデータを入力とする。そして、PointNet<sup>1)</sup>の手法を応用し、畳み込みおよび最大プーリングにより点群の順不同性を考慮した特徴量抽出を行う。その後、全結合層により特徴量から橋軸方向を表す 3 成分のベクトル量に変換を行う。中間の畳み込み層および全結合層の後には正規化処理としてバッチ正規化を、活性化関数として ReLU を挿入している。

学習の諸条件については表1に示す通りで、前述のサブサンプリングにより訓練、検証データを生成し使用した。また、損失関数についてはコサイン類似度をベースとして、橋軸方向の推定にあたっては逆ベクトルも正解とみなすことができるため、 $\cos$  を二乗することで考慮している。

#### 5. 橋軸方向の推定結果

検証データに対する推定結果を図4に示す。DNN は本モデル、PCA は主成分分析による推定結果である。対数軸の横軸  $\bar{d}_i$  はデータの空間的な範囲の大きさを示す指標として定義しており、小さいほど橋梁の一部分

表1 学習の条件、パラメータ

訓練データ数量	6 橋 × 682 サンプル
検証データ数量	2 橋 × 100 サンプル
点群の点数 $N$	8,000 点
損失関数	$loss = 1 - \cos^2(x_1, x_2)$
オプティマイザ	Adam(初期学習率: 0.001)
スケジューラ	20 エポック毎に学習率 1/2
ミニバッチサイズ	64
エポック数	200 回

しか含まれない点群であることを表している。縦軸は推定と真値のベクトルのなす角  $\theta$  で、小さいほど良好な推定結果と言える。全体として PCA に対して DNN の方が優れた推定精度である。特に  $\bar{d}_i$  が約 10m 以下の領域では DNN の方が優れた推定精度を示している。深層学習を用いることで一部分の点群からでも頑強性を有した推定が可能であると考えられる。

#### 6. まとめ

本稿では深層学習による点群の特徴量抽出手法を応用し、活用が期待できる構造的情報として橋軸方向を推定する回帰モデルを構築した。土木構造物の点群から取得したい情報を定義し、それに応じたデータセットやモデルを用意することで、より活用性の高い情報を抽出する可能性を確認した。

#### 参考文献

- 1) Charles R. Qi et al. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 77-85, 2017.
- 2) Ruodan Lu et al. Detection of Structural Components in Point Clouds of Existing RC Bridges. Computer-Aided Civil and Infrastructure Engineering, Volume 34, Issue 3, pp.191-212, 2019.