

点群深層学習に基づく法面の多時期・多点異常検知

大阪大学大学院工学研究科 学生員 ○石川 大智
大阪大学大学院工学研究科 正会員 貝戸 清之

1. はじめに

近年、i-Construction の推進に伴うレーザー計測技術の発展により、座標や色情報を有する点の集合である点群データの収集が容易化している。しかし、点群データは未だ十分に活用されているとはいえず、地物毎の変状や時系列変化などを容易に把握できないことが課題である。したがって、点群を処理可能な汎用的異常検知技術の開発がさらなる点群データの活用に資すると考えられる。また、実際の建設現場においても土工構造物の変状を簡易に確認可能な技術が求められている。現状では土工構造物の点検は近接目視によって行われているが、多大な労力を要することや点検者の暗黙知に頼る面が強いことが課題となっている。点検項目には、はらみ出し・移動量の計測などが含まれており、これらを簡易に検知できれば現場における業務の効率化に資すると考えられる。

このような中で、近年、深層学習の分野において、点群データを入力として分類や物体検出を行う技術である点群深層学習が研究されている。点群深層学習は未だ発展途上の技術であるが、点群における異常検知モデルの作成においても、点群深層学習における種々の要素技術は有効であると考えられる。本研究では点群深層学習を活用した法面における多時期・多点間の異常検知手法を提案する。

2. 本研究の基本的な考え方

(1) AutoEncoder による異常検知

AutoEncoder (以下、AE) とは入力と同じデータを復元するように重みを学習するニューラルネットワークであり、近年では異常検知などに用いられている。AE による異常検知では、はじめに正常データのみを用いて AE を訓練する。その後、新規データを訓練済みの AE に入力し、入力と復元との復元誤差を算出する。このとき、新規データが正常なものであれば、復元も正常なものであるため復元誤差が小さくなる。一方で、異常なも




図-1 PointAutoEncoder の構造

のであれば AE は正常データの特徴しか学習していないため、異常データを復元することができず誤差が大きくなる。したがって、復元誤差を確認することで入力 が正常であったか、異常であったかを判別可能である。

(2) PointNet

点群は画像のようにグリッドに固定された構造をもたないため、順序が一意に決定されない。したがって、点群をモデルの入力とする場合、入力の順序を任意に入れ替えたとしても出力が不変な構造 (順不変性) をもつ必要がある。PointNet¹⁾では、重みを共有した多層パーセプトロン (multi-layer perceptron, MLP) と MaxPooling により順不変性が獲得されており、本研究ではこの構造を AE に導入する。

3. 提案手法

本研究では、AE に順不変性を導入することで、入力に点群をとれるように拡張した PointAutoEncoder (以下、PAE) を用いる。図-1 に PAE の構造を示す。各数字は行列の列数を表す。エンコーダには PointNet における順不変性を満足する構造を採用した。1x1 畳み込み層はフィルタサイズ 1 の 1 次元畳み込み層であり、重みを共有した MLP と同等である。

損失関数には入力・再構成点群の非類似度を用いる必要がある。また、デコーダには順不変性を仮定しないため、損失関数により順不変性を考慮する必要がある。

キーワード：点群データ、深層学習、AutoEncoder、異常検知、土工構造物

連絡先：〒565-0871 大阪府吹田市山田丘 2-1 工学研究科 AR 棟 605 号室 TEL：06-6879-7622

そこで、次式で定義される Chamfer distance を用いた。

$$L_{CD} = \sum_{x \in S} \min_{\hat{x} \in \hat{S}} \|x - \hat{x}\|_2^2 + \sum_{\hat{x} \in \hat{S}} \min_{x \in S} \|x - \hat{x}\|_2^2 \quad (1)$$

また、各点の異常度 $R_i \in [0,1]$ を次式で定義した。

$$R_i = \frac{\min_{\hat{x} \in \hat{S}} \|x_i - \hat{x}\|_2^2}{\max_j \min_{\hat{x} \in \hat{S}} \|x_j - \hat{x}\|_2^2} \quad (i = 1, \dots, n) \quad (2)$$

4. 実証分析

(1) 多期間の異常検知

提案手法を MMS (mobile mapping system) により取得された法面点群データに適用した。データには、擬似的なはらみ出しを設ける前後の 2 時期のデータが存在する。擬似的なはらみ出しは縦横 25cm で厚さが 3cm, 2cm, 1cm と異なるものを 3 箇所設けた。取得された点数は、1 期データで 873,168 点、2 期データで 928,225 点となっており、データ量が膨大である。そこで、はらみ出し近傍の点群を、はらみ出しを含む法枠内から抽出した。点数はそれぞれ 8,163 点、9,034 点となった。それらから、それぞれ 2,048 点ずつランダムサンプリングを行い、544 個の正常サンプル、32 個の異常サンプルを作成した。512 個の正常サンプルを訓練データとし、残りの正常サンプル 32 個+異常サンプル 32 個をテストデータとした。

前処理として、各点群の座標値は $[0,1]$ の範囲に正規化した。エンコーダには 4 層の 1x1 畳み込み層、デコーダには 3 層の全結合層を用いた。エンコーダの全ての層とデコーダの最初の 2 層でバッチ正規化を行った。各層の活性化関数には ReLU を用いた。学習におけるエポック数は 600、バッチサイズは 32 とした。重みの最適化手法には Adam を用い、ハイパーパラメータの値は Kingma and Ba²⁾ の推奨値を用いた。訓練データを用いて PAE の訓練を行い、テストデータを入力して各点の異常度を算出した。図-2 に、はらみ出しを含む異常サンプルに提案モデルを適用した結果を示す。3cm, 2cm はらみともに各点異常度は高い値を示しており、目視でも困難なはらみ出しを検知できている。

(2) 多点間の異常検知

次に (1) で訓練したモデルの同時期における多点間の異常検知への適用性を検討した。訓練に用いていない 1 期データの法枠から (1) と同様に 2,048 点ずつランダムサンプリングを行い、同様の前処理を行ったうえ




図-2 法面データにおける入力、再構成、異常度

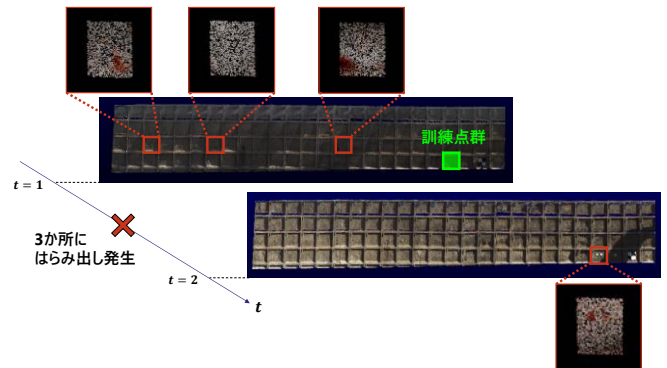


図-3 多時期・多点間異常検知

で訓練済みモデルに入力し、異常度を算出した。図-3 に (1) における異常検知結果を含め、多点間の異常検知結果の例を示す。示した 3 点のうち、1 点では異常がなく、2 点では異常度の高い箇所がみられている。これにより、初期はらみや施工不良を検知し、初期点検時以降にどの箇所に注意を払うべきかを知ることができる。特に、法面上部の法枠内は高所作業車やロープアクセスによる点検が必要となるため、点検箇所をスクリーニングすることは有用であるといえる。

5. おわりに

本研究では、異常検知に用いられる深層学習モデルである AE を入力に点群をとれるように拡張し、法面の局所的異常検知を実データに基づいて行うことで、多時期・多点間の異常検知可能性を検証した。今後ははらみ出し以外の局所的異常への適用可能性やオクルージョンによる欠損への対応を検討する必要がある。

【参考文献】

- 1) C. R. Qi, H. Su, K. Mo and L. J. Guibas : PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation, *Computer Vision and Pattern Recognition*, pp.652-660, 2017.
- 2) D. P. Kingma and J. Ba : Adam: A method for stochastic optimization, *International Conference on Learning Representations*, pp.1-13, 2015.