

第VI部門

点群深層学習に基づく斜面の局所的異常検知

大阪大学工学部

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 の推進による設計から維持管理に至るまでの高度化の流れに伴って、レーザー計測技術が発展しており、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、大規模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あ資すると考えられる。また、現状では土工構造物の点検は近接目視点検によって行われている。これには多大な労力を要することが問題視されており、近接目視によらず土工構造物の変状の有無を確認可能な技術が求められている。近接目視点検の中には、はらみ出し・移動量の計測などが含まれており、これらの変状を簡単に検知できれば業務の効率化につながると考えられる。

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。そこで、本研究では点群深層学習を活用して点群を処理可能な異常検知技術を開発する。

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、図-1 に示すように、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




図-1 AutoEncoder による異常検知




図-2 PointAutoEncoder の構造

る。一方で、異常なものであれば 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

点群は画像など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-2 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。

損失関数には入力点群と再構成点群の非類似度を設定する必要がある。また、デコーダには順不変性を考慮しないため、損失関数により順不変性を考慮する必要がある。そこで、次式で定義される Chamfer distance を用いた。

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

L_{CD} は互いに一方の点群の各点に対し他方の点群における最近傍点を探索し、それらの間の平方距離を足し合わせたものである。また、各点 x_i における異常度を次式で定義した。

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

4. 実証分析

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 (それぞれ正常データ、異常データと呼ぶ) 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ともに 25cm で厚さが 3cm, 2cm, 1cm と異なるものを 3 箇所設けた。取得された点群数は、正常データで 873,168 点、異常データで 928,225 点となっており、データ量が膨大である。そこで、はらみ出し近傍のデータを、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 点の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。ランダムサンプリングにより、多時期計測で得られる点にずれが生じることを再現し、各点群データにそれぞれ異なる時期に計測されたものであるという意味づけを行った。

前処理として、各点群データの座標値は [0,1] の範囲に正規化した。図-2 に示すように、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




図-3 法面データにおける入力、再構成、異常度

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-3 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。また、点数は入力と再構成で等しいにも関わらず、再構成点群においては入力点群よりも密な点群が得られているように思われる。これは、再構成点群においては、PAE により正常データの特徴として曲面内に位置するという情報が学習されたためであると考えられる。これにより再構成点群においては、より纏まりをもって曲面内に位置するように再構成されている。

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た。また、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、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.