

(12) 点群深層学習を用いた 水中構造物の分類における精度検証

八木 笙太¹・大川 博史²・樫山 和男³

¹学生会員 中央大学大学院 理工学研究科 都市人間環境学専攻 (〒112-8551 文京区春日 1-13-27)

E-mail: a16.365j@g.chuo-u.ac.jp

²正会員 株式会社エイト日本技術開発 技術本部 (〒164-8601 東京都中野区本町 5-33-11)

E-mail: ookawa-hi@ej-hds.co.jp

³正会員 中央大学教授 理工学部 都市環境学科 (〒112-8551 東京都文京区春日 1-13-27)

E-mail: kaz@civil.chuo-u.ac.jp

本論文は、自律航行型無人ロボット(Autonomous Surface Vehicle : 以後 ASV とする)を用いて取得した水中マッピングデータにおいて、ナローマルチビームソナーにより取得した点群データと点群深層学習手法を用いて、水中に存在する構造物を自動的に迅速かつ正確に判別し、水中の現況把握を行う手法の構築を目的としたものである。本論文では、データ特性を活かした学習データの作成を行い、使用する点群深層学習フレームワークによる影響や、マッピングデータから取得した点群データに対し、表面の再構成を行うことによる影響、学習実行時の入力点数の差異による影響を示し、テストデータに対する正解率の評価を行った。

Key Words: mapping data, ASV, deep learning, point cloud, PointNet++

1. はじめに

近年、センシング技術の発展はソフトとハードの両面で著しく、難易度が高く危険な作業を伴う水中での作業が容易となった。そのため、漁港・港湾施設ではセンシング技術を活用した点検技術の検討が数多く行われている¹⁾。例えば、水中構造物の形状や水底の洗掘においては、音響探査機に加え、ASV といった無人ロボットを用いることで、簡易で安全かつ高精細に行うことが可能となった²⁾。更に、高品質な水中マッピングデータの作成が従来と比較して格段に容易となっている。一方で、水中マッピングデータはそのデータ量が膨大であること、色彩情報を持たないといった判読性の低いデータである。そのため、水中マッピングデータの高度な利活用では、計測データの分析において、専門技術員による判読が必要であることや、その過程において発生する人為的ミスが課題とされている。

本研究の目的は、深層学習を用いて、水中マッピングデータから、水中に存在する構造物を迅速かつ正確に自動判別し、水中の現況把握を行う手法の構築をするものとする。

本論文では、上記の目的を達成するため、点群深層学習による水中構造物の分類モデルの構築を行った。対象を水中マッピングデータ内に存在する構造物の点群データとし、分類時の正解率に対する点群深層学習フレームワークによる影響や、取得したデータに対する前処理の影響、入力点数を減らすことによる影響に関する検証を行った。

2. 使用データ

(1) 計測方法と計測データ

本論文では、ASV をプラットフォームとして水中マッピングデータにおいて、ASV に搭載したナローマルチビームソナーにより得られる水中点群データを使用し分析を行う。

マッピングデータとは、地理的な位置情報に基づき、様々な情報を付与したデータのことを指し、水中マッピングデータとは、水中で取得した画像や地形、水質や時間などのデータに加えて位置座標データを付与したものである。

本論文では、水中マッピングデータから得られる点群データを使用するが、水中の点群データは色彩情報である RGB 値を持たないため、三次元の座標値のみを取り扱う。

調査対象区域として、鳥取県隠岐島来居港および島根県浜田市浜田港を取り上げた。ナローマルチビームソナーで取得した水中マッピングデータの一部領域を図-1に示す。分類対象として二種類の消波ブロックを取り上げる。データ取得後、点群処理ソフト (CloudCompare³⁾) を用いて、各ブロックの点群データを任意に抽出した。抽出したブロックの一例を図-2 に示す。分類対象のブロックは図の通り、それぞれブロック A、ブロック B とする。

(2) テストデータ

本論文では、テストデータとして抽出したブロックデータを用いる。しかし、抽出した点群データはノイズを多く含むデータであり、水面から水底に向けてビームを発しているため、影となる部分のデータは欠損している。そこで、点群の再構成手法である WLOP (Weighted Locally Optimal Projection⁴⁾) の適用を行った。

WLOP は、式(1)を k 回反復計算することで、入力点群 $P = p_j$ に対する射影点群 $X = x_i$ を生成する手法である。

$$x_i^{k+1} = \sum_{j \in J} p_j \frac{\alpha_{ij}^k / v_j}{\sum_{j \in J} (\alpha_{ij}^k / v_j)} + \mu \sum_{i' \in I \setminus \{i\}} \delta_{ii'}^k \frac{w_{i'}^k \beta_{ii'}^k}{\sum_{i' \in I \setminus \{i\}} (w_{i'}^k \beta_{ii'}^k)} \quad (1)$$

この時、 $\delta_{ii'}^k = x_i^k - x_{i'}^k$ である。式(1)中の第一項は入力点群への吸着項であり、第二項は射影後の点群を均一に保つための反発項である。また、パラメータ $v_j, w_{i'}^k$ は、第一項、第二項それぞれに対して積算される近傍点群の密度による重みである。


図-2 に示す分類対象のブロック A、B それぞれに対して、WLOP を適用した点群モデルを図-3 に示す。本論文ではテストデータに対する WLOP の適用の有無による分類精度への影響の比較を行った。

(3) トレーニングデータ

本論文では、トレーニングデータとして、CAD モデルから生成した点群データを用いる。分類対象の各ブロックは既製品であることから、設計図面に基づき CAD モデルを作成した。CAD モデルに対し、点群処理ソフトを用いて生成した点群モデルを図-4 に示す。各モデルを構成する総点数は約 3,000 点である。




図-1 水中マッピングデータ(点群+反射強度)



ブロック A

ブロック B


図-2 水中マッピングデータから抽出した点群モデル



ブロック A

ブロック B

図-3 WLOP適用後の点群モデル



ブロック A

ブロック B

図-4 CADモデルから生成した点群モデル

3. 点群深層学習による物体分類

(1) 点群深層学習

深層学習は、機械学習手法の一つであり、人間の脳神経細胞を模したニューラルネットワークを用いて学習を行う手法である。深層学習で広く利用される畳み込みニュー

ーラルネットワーク（Convolutional Neural Network: CNN）は二次元の画像分類を対象としたモデルであり、そのフレームワークを単純に拡張することで、三次元の点群データに対して直接適用することは困難である。三次元のデータに対してはボクセル化といったアプローチ⁹⁾もあるが、本論文では分類精度を重視し、点群データを直接入力データとして扱う。

(2) 点群深層学習フレームワーク

本論文で用いる点群深層学習フレームワークである PointNet⁶⁾と PointNet++⁷⁾のネットワーク構成図を図-5に示す。

PointNet では、点群データを直接入力データとするため、二つの特徴を持つ。一つ目は T-Net 部分におけるアフィン変換行列の適用であり、これにより点群モデルが移動・回転しても種類が変わらないという剛体変換不変性を獲得している。また、二つ目は MaxPooling 層や全結合層といった対称関数でネットワークを構成することにより、点群データ内の順番による影響を無くしていることである。

PointNet++では PointNet で課題であった入力点群データの局所構造を考慮するため、新たに点密度に応じてマルチスケール情報を得る二つの抽象層を提案している。一つ目はサンプリング層であり、距離空間におけるサンプリングを行う。FPS (Farthest Point Sampling) を用いて入力点群から均等感覚に代表点となる点を n 個選択する。次に二つ目のグルーピング層では、FPS で選択されなかった点群に対して、FPS で選ばれた点群 n の中で最も近いグループに振り分ける。本論文ではグルーピング層には SSG (Single Scale Grouping) を適用した。これら二層と従来の PointNet を再帰的に適用することで、マルチスケール情報を集約し、点群の局所構造を考慮した深層学習フレームワークを構築している。

本論文では、トレーニングデータおよびテストデータ内の各点群モデルにおける局所構造が、分類精度に及ぼす影響を検証するため、PointNet と PointNet++による精度比較を行う。


4. 適用例

(1) 入力データと前処理

学習に用いるトレーニングデータとテストデータの間を表-1に示す。

トレーニングデータは CAD モデルから作成した点群データを用いる。分類対象のブロック A・B に対して、総点数が 2,500 点となるようにランダムにサンプリングした点群データを各 100 個用意した。

【PointNet※構成図】



【PointNet++構成図】

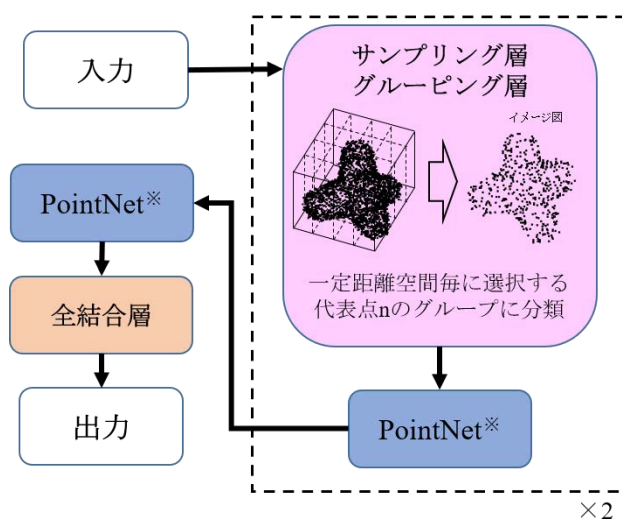


図-5 深層学習フレームワーク構成図

表-1 入力データ

学習用データ	トレーニングデータ	テストデータ
検出対象		
ブロックA 	100個 (CADモデルから生成)	25個 (取得データから抽出)
ブロックB 	100個 (CADモデルから生成)	80個 (取得データから抽出)

テストデータには取得した水中マッピングデータから任意に抽出したデータおよび、更にWLOPを適用したデータを用いる。WLOPにおける反復回数 k は 30 とし、生成後の点群の総点数をトレーニングデータと同様に 2,500 点に設定した。テストデータ数はそれぞれ、ブロック A が 25 個、ブロック B が 80 個である。

(2) 学習条件

計算開発環境は、ハードウェア環境は CPU : Intel Corei9-9900k 3.60GHz / GPU : GeForce RTX 2080 / OS : Windows10 / RAM : 32.0GB であり、ソフトウェア環境は、Anaconda3 上の Python3.6/Pytorch においてプログラムを実行する。

入力点数は基本を 1024 点、学習回数は 20 回として以下の条件において比較を行う。

- 条件 1 : 深層学習フレームワークに PointNet を採用した場合と PointNet++を採用した場合の計算時間と正解率の比較
- 条件 2 : 条件 1 加え、テストデータに対して WLOP の適用の有無による計算時間と正解率の比較
- 条件 3 : 条件 2 までにおいて優位であった事象に加え、入力点数を 64,128,256,512,1024 と変化させた場合における正解率の比較

(3) 結果と考察

図-6、図-7 に各条件における結果を示す。

条件1では、PointNet++を用いて入力データの点群密度を考慮することにより、学習時間は倍以上となったが、正解率は 10%近い向上が見られた。そのため、分類精度を重視した場合、点群密度の考慮は分類に影響を及ぼすため、深層学習フレームワークには、PointNet++が有効であると考えられる。




図-6 深層学習フレームワークの違いと WLOP の有無による比較 (条件 1・2)




図-7 入力点数の違いによる比較 (条件 3)

条件 2 においては、WLOP を適用し、テストデータにおける外れ値やノイズデータを除去することによって、学習が効率化され、正解率と計算時間ともに向上が見られた。そのため、取得したテストデータに対しては、適切な前処理を適用することが分類精度の確保において重要であると考えられる。

条件 3 では、PointNet++、WLOP を採用し、比較を行った。入力点数が 256 点までの場合、正解率は高水準を保っていることから、対象の形状情報が分類に重要であり、学習実行時の入力点数が少ない場合においても分類精度を確保できると考えられる。

5. おわりに

本論文では、ASV を用いて取得した水中マッピングデータにおいて、点群データおよび点群深層学習手法を用いて、消波ブロックを対象とした水中構造物の分類における正解率の検証を行った。結論として、分類精度の確保には学習時の入力点数には大きく依存せず、対象の形状情報を捉えることが重要であると確認した。

今後は、汎用性向上を目的とし、分類対象ブロックの追加、他の前処理手法の検討、およびセグメンテーションの利用について検討していく予定である。

参考文献

- 1) 三上信雄, 梅津啓史, 松本力, 完山暢, 大西明夫, 不動雅之, 井上真仁 : 漁港施設の水中部の点検手法におけるナローマルチビームソナーの適用性検証, 土木学会論文集 B3(海洋開発), Vol.75, No.2, pp. I_91-I_96, 2019.
- 2) 澤隆雄, 大木健 : 海底マッピングにおける海洋音響技術, 日本音響学会誌, Vol.75, No.2, pp.29-34, 2019.
- 3) Cloud Compare ver.2.12 alpha, <<https://www.cloudcompare.org/>>, (入手 2021.6.2).
- 4) Huang, H., Li, D., Zhang, H., Ascher, U. and Cohen-Or, D. : Consolidation of Unorganized Point Clouds for Surface Reconstruction, *ACM transactions on graphics*, Vol.28, No.5, pp.1-7, 2009.
- 5) Zhou, Y. and Tuzel, O. : VoxelNet : End-to-End Learning for Point Cloud Based 3D Object Detection, *Computer Vision and Pattern Recognition*, pp. 4490-4499, 2018.
- 6) Qi, C.R., Su, H., Mo, K. and Guibas, L.J. : PointNet : Deep Learning on Point Sets for 3D Classification and Segmentation, *Computer Vision and Pattern Recognition*, pp. 652-660, 2016.
- 7) Qi, C.R., Yi, L., Su, H. and Guibas, L.J. : PointNet++ : Deep Hierarchical Feature Learning on Point Sets in a Metric Space, *In Advances in neural information processing systems*, pp. 5099-5108, 2017.