

点群深層学習を用いた水中構造物の検出と可視化

中央大学大学院 学生会員 ○ 八木 笙太
 (株) エイト日本技術開発 正会員 大川 博史
 中央大学 正会員 檜山 和男

1. はじめに

近年、国土交通省の推進する BIM/CIM, i-Construction といった取り組みにより、漁港・港湾施設における ICT の活用は一層活発化している¹⁾。水中マッピング技術の分野では、音響測深機や無人ロボットといったセンシング技術の発展に伴い、水中マッピングデータの品質が向上している²⁾。一方で、水中マッピングデータは位置情報に加え、地形や時間情報等を含む膨大なデータであり、一般に判読性に劣るデータである。そのため、水中マッピングデータの高度な活用には、測定データの読み取りや解析に専門の技術者が必要であり、その過程で発生するヒューマンエラーが課題となっている。

そこで本研究では、上記の問題に対応するため、深層学習モデルによる点群データの色付けを行い、データ分析の高速化や省力化を目的とする。

本発表は、水中マッピングデータの中でも点群データを利用して、検出モデルによるトレーニングデータの評価を行った後に、セマンティックセグメンテーションモデルによる色付けを行うものである。

2. 点群深層学習手法

(1) 点群データ

本発表で用いる水中点群データの一例を図-1 に示す。取得した水中点群データは、色情報を持たず、3次元の座標値データおよび反射強度パラメータのみを持つ。

取得した水中点群データから検出対象とする2種の消波ブロックの名称をそれぞれブロック A、ブロック B とする。ブロックの一例を図-2 に示す。

(2) 点群深層学習フレームワーク

本発表では水中点群データの内、座標値データを入力データとした消波ブロックの検出モデルおよびセマンティックセグメンテーションモデルを構築する。深層学習フレームワークには、点群データを入力データとし、検出タスクとセマンティックセグメンテーションタスクに対応することが可能である PointNet++³⁾ を用いる。PointNet++ では両タスクにおける入力データの特徴学習箇所が一致するため、計算が容易な検出モデルによる学習データの評価を行った上で、セマンティックセグメンテーションモデルによる色付けを図る。

3. 適用例

(1) 入力データの作成と前処理

本研究では、水中点群データから抽出した各ブロックの点群データをテストデータとして、消波ブロックの CAD



図-1 水中マッピングデータ例 (点群 + 反射強度)

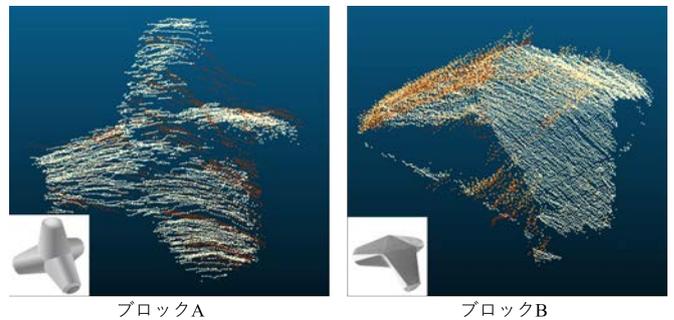


図-2 検出対象のブロック

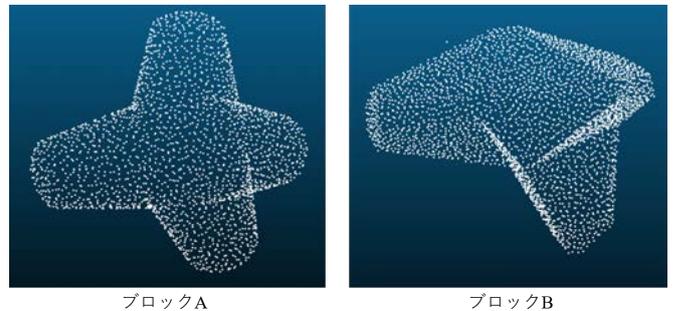


図-3 CAD データから作成した点群モデル

データから作成した点群データをトレーニングデータとして使用する。作成したトレーニングデータの一例を図-3 に示す。検出モデルにおけるテストデータの抽出には、取得した水中点群データから点群処理ソフトを用いて、ブロック A を 115 個、ブロック B を 54 個抽出した。また、検出対象のブロックは全て 3,000 点以上の点群から構成される。

水中点群データはその取得方法の都合上、水面から影や死角となる部分は欠損しているブロックデータが数多く含まれる。そのため、トレーニングデータである CAD データを加工することによって、検出精度を高める工夫を施した。

KeyWords : 水中マッピングデータ, 点群データ, 深層学習, PointNet++

連絡先 : 〒112-8551 東京都文京区春日 1-13-27 TEL : 03-3817-1815 E-mail a16.365j@g.chuo-u.ac.jp

テストデータを考慮して作成したブロック A, およびブロック B のトレーニングデータの各種類を図-4 に示す. テストデータの形状を考慮した結果, トレーニングデータに含まれる各ブロックの形状候補数は, ブロック A が 6 種類, ブロック B が 3 種類となった.

また, セマンティックセグメンテーション用のテストデータには取得した水中点群データの領域を分割して用いる. トレーニングデータには, 加工したブロックを利用して作成する領域データを用いる.

(2) 学習条件

検出モデルの学習に用いるテストデータ数はブロック A が 115 個, ブロック B が 54 個である. 深層学習フレームワークとして PointNet++ を使用し, 入力点数は 1024 点, 学習回数は 50 回として学習を行う. 学習時の比較条件を以下に示す.

- 条件 1: 図-3 に示す, 未加工の点群モデルをトレーニングデータとして各 50 個の計 100 個用いる学習
- 条件 2: 図-4 に示す, グループ I と II の点群モデルを各 50 個の計 450 個用いる学習
- 条件 3: 条件 2 において, グループ II のデータ数を各 20 個とした, 計 330 個のトレーニングデータを用いる学習

評価方法として学習実行時の正解率の推移による評価と, 学習後に正解率が最も高い地点を用いた混同行列による評価を行う.

また, セマンティックセグメンテーションでは深層学習フレームワークとして PointNet++ を使用し, 入力点数は 2048 点, 学習回数は 32 回として学習を行う.

(3) 結果

図-5 に学習時の正解率の推移のグラフを示す. 図-6 に混同行列による条件 1 から条件 3 までの評価グラフを示す.

図-5 より, 学習はおおよそ収束していることが確認できる. また, データ加工による影響を十分に確認できるほか, データ量の調整によっても平均して 10% 程度の正解率の上昇が見られた. また, 図-6 の混同行列による評価から, 条件 3 においては, 検出可能なブロックが偏ることがなく, バランスよく検出できていることが確認できる.

セマンティックセグメンテーションにおけるトレーニングデータの作成と色付けの結果に関しては, 講演時に示すものとする.

4. おわりに

本発表では, 水中マッピングデータ内の点群データを用いて, 消波ブロックを対象とした点群深層学習手法による検出モデルの構築とセマンティックセグメンテーションを用いた色付けを行った. 結論として, データの形状の工夫やデータ量の工夫によって精度が大きく向上することを確認した.

今後は, 構築した両学習モデルの汎化性能の検証を行っていく予定である.

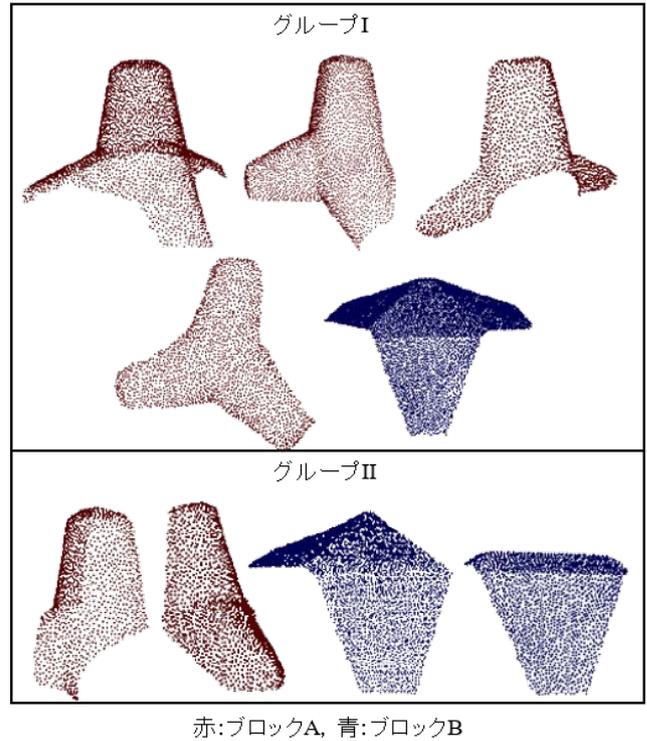


図-4 加工した各種類のトレーニングデータ



図-5 検出モデルの学習推移

		予測 [個]								
		条件 1			条件 2			条件 3		
		A	B	再現率	A	B	再現率	A	B	再現率
実際 [個]	A	15 / 115	100 / 115	0.13	90 / 115	25 / 115	0.78	96 / 115	19 / 115	0.83
	B	10 / 54	44 / 54	0.81	25 / 54	29 / 54	0.54	9 / 54	45 / 54	0.83
適合率		0.6	0.31		0.78	0.54		0.91	0.7	

図-6 混同行列による評価

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. L91-L96, 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) 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.