

水中心群データにおける消波ブロックの検出

中央大学大学院 学生員 ○ 八木 笙太
 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、漁港・港湾施設においてはセンシング技術を活用した点検技術の検討が行われている¹⁾。センシング技術の発展は著しく、水中においては簡易で安価かつ高精細に水中構造物の形状や水底の洗堀、土砂体積状況の確認が可能となった。また、それにより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²⁾。しかし、水中マッピングデータは膨大なデータであり、データ取得後の処理において、専門技術員による判読に頼るなど、高度に利活用する際に障害がある。

本研究の目的は、取得した水中マッピングデータにおいて、点群データと自動化や省力化に大きく貢献できる深層学習を用い、水中に存在する物体を自動的に迅速かつ正確に判別し、水中の現況把握を補佐する手法の構築をするものである。

本稿では水中心群データ内に存在する消波ブロックを対象として、点群深層学習による識別モデルの構築を行い、その学習モデルの評価、および学習データの作成の効率化について報告する。

2. 識別モデルの構築

図-1 に識別モデル構築の流れのフローチャートを示す。

(1) 入力データ

本稿では ASV(Autonomous Surface Vehicle) をプラットフォームとして、ナローマルチビームソナーを搭載し、取得した水中マッピングデータから得られた点群データを使用する。

点群データは地理的な位置情報や色情報を保持することが出来るが、本稿では水中を対象としており、位置情報のみのデータを用いて識別モデルを構築する。また、点群データはそのモデルデータに順序性がないことや隣接関係が自明にならないといった、不規則な空間的關係を持つ。

(2) データの前処理

学習用データ作成のため、取得した水中心群データから検出対象である消波ブロックを構成する点群データのみを点群処理ソフトである CloudCompare³⁾ を用いて手作業にて一つずつ抽出した。抽出した消波ブロックの点群データ例を図-2 に示す。

今回抽出した消波ブロックの数はそれぞれ図-2 中のブロック A を 80 個、ブロック B を 25 個とした。また、各ブロックの点群は 1,000 点から 15,000 点程度の数で構成されている。

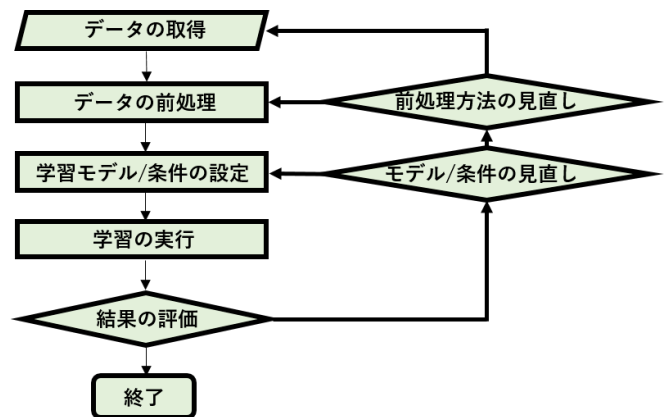



図-1 識別モデル構築の流れ



ブロックA

ブロックB

図-2 抽出した消波ブロックモデルデータ

また、学習実行時には、プログラム内において、各消波ブロックに対して、各点群データの総点数の統一および軽量化を目的としたサンプリングや、データ形式の統一を目的とした正規化、またデータの多様性や汎化性能の確保を目的としたノイズ付与や回転処理によるデータ拡張を施している。

(3) 使用した学習モデル

人間の脳神経細胞を模倣したニューラルネットワークを用いて学習する機械学習手法の一つである深層学習を用いる。点群データでは、その空間的關係から、既存の二次元で用いられてきた画像分類のフレームワークを拡張し、三次元の点群データに適用することは困難である。そのため、生の点群データを入力データとして学習を行うことが可能である PointNet⁴⁾ を用いる。

PointNet では点群の空間的關係を最大限利用するために二つの点群処理方式を導入している。一つ目は点群の特性である順序や隣接関係といった影響の排除を目的とした全結合層や MaxPooling 層といった対称関数の採用である。

KeyWords : 深層学習, 水中マッピング, 消波ブロック

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

これにより全てのポイントを平等に扱っている。二つ目は回転による影響の除去を目的とした点群へのアフィン行列の採用である。本稿ではこの PointNet を用いて識別モデルの構築を行った。

(4) 学習条件の設定

学習データの作成には、交差検証法を用い、抽出した消波ブロックデータを学習用データ、検証用データに分割した。ブロック A に関しては、抽出した 25 個のデータの内、10 個を検証用データにし、残り 15 個を複製し、2 倍にした 30 個を学習用データとした。ブロック B に関しても同様に、抽出した 80 個のデータの内、20 個を検証用データにし、残り 60 個を 2 倍に複製した 120 個を学習用データとした。

ネットワークには先述した PointNet を用いて、学習回数は 15 回として学習を行った。

(5) 結果

学習における正解率と誤差量の推移を図-3 に示す。学習回数 8 回目を超えた時点から正解率、誤差量共に値の収束が見られ始め、学習回数 9 回目、15 回目では検証用データに対する正解率が 100% になる点が見られた。

学習終了後、正解率 100% となった学習回数 15 回目時点の重みを用いて再度検証用データに対する評価を行った。結果を混同行列にて表示したものを図-4 に示す。正解率 100% 時点の重みを適用することで、検証用データに対し十分な精度結果を示した。また、高い正解率の要因として、個々の消波ブロックモデルの形状差が小さく、学習が容易である点が影響していると予想される。

3. 学習データ作成の効率化

個々の消波ブロックの形状差が小さい点に着目し、3DCAD ソフトで作成した各消波ブロックの 3D モデルからその点群モデルを作成し、モデルを構成している点をランダムに抽出することによる学習データの作成を試みた。

ブロック A に関して、モデルを作成し、抽出した 25 個のブロックデータを検証用データとし、モデルから生成した 120 個のデータを学習用データとして学習を行った。

結果として、学習データを手作業にて抽出する手間が省け、多くのデータを簡単に用意する事が可能となったが、図-5 に示すように高い正解率を維持することが困難となった。

これは検出用データに含まれる実際に計測機器によって取得したデータから抽出した消波ブロックモデルは、表面形状のみを捉えたデータであり、検証用データの中にはモデルの一部が欠損しているデータも数多くあるため、作成したモデルと形状が一致しない点が原因であると予想される。そのため、学習データの作成時に適切な前処理が求められ、前処理手法について検討を行っている。前処理手法の詳細と結果については講演時に示す。




図-3 学習の推移

	予測	モデルA	モデルB
正解			
モデルA		10 個	0 個
モデルB		0 個	20 個

図-4 学習結果

	予測	モデルA	モデルB
正解			
モデルA		12 個	13 個
モデルB		0 個	20 個

図-5 作成した学習データを用いた学習結果

4. おわりに

本稿では、水中心群データにおける消波ブロックを対象とした点群深層学習による識別モデルの構築を示した。結果として、水中心群データを用いた点群深層学習による物体判別が可能であることを確認し、対象とした消波ブロックには形状の個体差が少ないことから、高い正解率に結びついたことを確認した。

今後は、データ作成の効率化および汎化性能の検証、また水中心群データから消波ブロックを検出するための領域検出手法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, 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, 第 75 号 1 巻, pp29-34, 2019.
- 3) Cloud Compare: <https://www.cloudcompare.org/>, 2021 年 3 月閲覧
- 4) Qi, C.R., Su, H., Mo, K. and Guibas, L.J, PointNet: Deep learning on point sets for 3d classification and segmentation, CVPR, 2017.