

## (19) CAD モデルを用いた三次元点群深層学習に基づく水中構造物の物体分類

大川 博史<sup>1</sup>・八木 笙太<sup>2</sup>・板野 誠司<sup>3</sup>・檜山 和男<sup>4</sup>

<sup>1</sup>正会員 株式会社エイト日本技術開発 技術本部 EJ イノベーション技術センター  
(〒164-8601 東京都中野区本町 5-33-11)

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

<sup>2</sup>正会員 株式会社エイト日本技術開発 防災保全事業部  
(〒700-8617 岡山県岡山市北区津島京町 3-1-21)

E-mail: yagi-sho@ej-hds.co.jp

<sup>3</sup>非会員 株式会社エイト日本技術開発 国土インフラ事業部  
(〒700-8617 岡山県岡山市北区津島京町 3-1-21)

E-mail: itano-se@ej-hds.co.jp

<sup>4</sup>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に装着したナローマルチビーム測深機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、水中構造物のうち、既製の水中構造物においては3DCADモデルから学習データの作成を行うことにより、学習データ収集の省力化および正解精度を向上させる方法を提案する。点群深層学習フレームワークを本手法により作成した水中点群データに適用し、正解精度を比較することにより影響評価を行った。

**Key Words:** point cloud, deep learning, underwater structure, multibeam echo-sounding, classification

### 1. はじめに

三次元計測機器の普及により、陸上の点群計測技術の飛躍的な発展を端緒として、水中においても音響機器を活用した点群計測技術は発展の一途をたどっている。

水中の新しい点検技術として、これまでの潜水士による目視点検等に代わり、自律航行型無人ロボット (Autonomous Surface Vehicle : 以後 ASV とする) に音響測深機を装着・計測することで、広範囲を簡易・安全かつ高精細なデータを取得することが可能となった。一方で、これらの取得された水中マッピングデータ<sup>1)</sup>の問題点として、データ量が極めて膨大となること、色彩情報を持たず判読性の低いデータであることが挙げられる。そのため、水中マッピングデータは計測データ分析時に専門技術員の判読が必要であるだけでなく判読に時間がかかり、その過程で人為的ミスも発生しやすいといった課題がある。

本研究では、これらの課題に対応するため、陸上点群データにおいて利用されているPointNet++<sup>2)</sup>を水中点群データへ適用し、点群深層学習に基づくセマンティックセグメンテーションモデルによる点群データの色付けを行うことで自動的かつ高精度な判別を行った。また、既製の水中構造物について3DCADモデルに点群を発生させ、学習データとすることでデータ収集の高効率化と精度の向上を実現する方法を提案する。本手法で生成した学習データを用いて、点群深層学習フレームワークにて水中点群データを分類し、正解率を比較することで影響評価を行った。

### 2. 水中点群データおよびデータ取得方法

#### (1) 使用機材

水中マッピングデータは、水中で取得した画像や地形、

水質や時間などのデータと位置座標を付加したデータである。これらの水中マッピングデータの取得方法として、船舶にサイドスキャンソナーやマルチビームエコーサウンダーなどの音響探査装置を搭載し、計測するのが一般的である。

本研究では、ASV (図-1 参照) をプラットフォームとして搭載されたセンサーのうち、マルチビーム音響測深機 (iWBMSH ; Norbit 製) を用いることで、点群データを取得することが可能である。

## (2) 水中点群データの取得

水底面を把握する手法には、直接的手法と間接的手法があるが、本研究では、間接的手法の1つで、マルチビーム深浅測量はミルズクロス方式により計測されている。この方式はソナーから扇状の送波ビームを横方向に発振し、水底に反射して戻ってくる受波を縦方向のスリットで受信するものである<sup>3)</sup>。この送波と受波がクロスした部分が計測する各点となり、受信部の複数のスリットにより、1回の発振で多数の点群を同時取得している。このマルチビーム測深機を ASV に搭載することによって点群データを取得しており、実際に取得した点群データ例を図-2 に示す。なお、水中の点群データは色彩情報を持たないため、三次元の座標値のみを取り扱う。

## (3) 点群データについて

点群(Point Cloud)とは、一般にレーザースキャナー等で計測される点の集合データである。各点は位置情報や、色彩、反射強度といった情報を持つことができ、物体表面や形状についても全て位置情報のみで表現され、その物体内部の状況は反映しない。また、点群データの特性として、順序がなく隣接関係が不明瞭であるといった順不変性や点群の移動や回転といった処理が施された場合においてもその物体の種類が変化しないといった移動不変性をもつ。そのため、深層学習モデルの構築において、点群データを入力データとして用いる場合、これらの特性に留意する必要がある。

本研究にて使用する水中点群データは、前節に記述したとおり、三次元の位置情報のみを有する。そのため、陸上で計測された点群データのように RGB の色彩情報等から特徴量を抽出することは不可能である。

## 3. 三次元点群深層学習による物体認識

### (1) 三次元点群深層学習について

三次元点群は前述の通り三次元座標情報を持った多数の点によって三次元モデルを形成する。一方、三次元点群は単なる点の集合であるため、これらの点には順序が



### マルチビーム測深機の諸元

- 名称: iWBMSH (Norbit 社製)
- ・スワ幅: 7-210°
  - ・測深分解能: 10mm 未満 (Acoustic)
  - ・ビーム数: Min 256~Max 512
  - ・測深レンジ: 0.2-275m

図-1 ASV およびマルチビーム測深機諸元




図-2 取得データ (※標高別に分)

存在しないという性質がある。また、各点は一定の間隔で分布しているとは限らない。点の密度が一定ではないため、点同士の隣接関係が不明瞭である。しかしながら、単一の点では特に意味を持たず、近接した複数の点によって三次元形状を表現するため、近接する点同士の位置関係が極めて重要である。このような性質を考慮し深層学習を行うには、三次元点群を特定の手法によって画像変換し、畳み込みニューラルネットワーク (Convolutional Neural Network : CNN) で学習を行うという画像ベースの手法<sup>4)</sup>が一般的であった。しかし、三次元データを二次元データに変換という処理によって、本来の詳細な幾何学的・空間的情報が失われたり、変化したりする。そのため近年では、三次元点群を画像化せずに直接入力・学習させる三次元点群ベースの手法が主流となっている。

### (2) 三次元点群深層学習モデルについて

三次元点群を直接入力データとして扱うためには、前節で述べた三次元点群の特性を考慮した処理をどのように行うかが課題であった。PointNet<sup>5)</sup>は、三次元点群の点に順序がないという性質を考慮し、三次元点群データを直接入力可能にするニューラルネットワークである。PointNet は、入力の順番が変わっても出力が変わらない

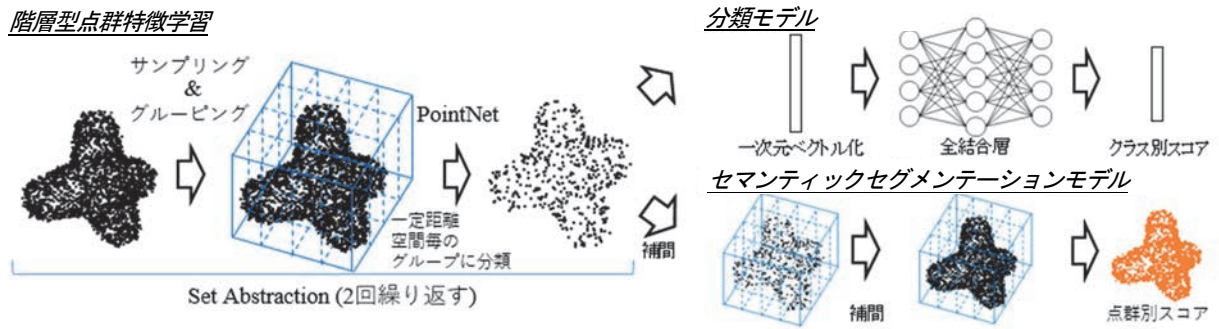


図-3 使用ネットワーク (PointNet++) 構成図

という性質を持つ対称関数に着目し、対称関数の1つである Max pooling を取り入れることで点の順序不同性に対処している。一方、PointNet++ (図-3 参照) は、PointNet の改良版として Qi が提案したニューラルネットワークで、PointNet は三次元点群の集合を直接入力することで学習できるが、局所的な特徴を抽出できないという問題があった。この問題を解消するため、PointNet++では、局所領域ごとに特徴が抽出される階層的なネットワーク構造を有している。局所特徴量の抽出部は、サンプリング層、グルーピング層、PointNet 層の3層から構成される。サンプリング層は入力した三次元点群を抽出し、グルーピング層はサンプリング点を中心とした近傍点をグループ化する。また、PointNet 層は抽出された近傍点から特徴量を計算する。これらの処理によって入力された三次元点群の局所的な特徴を学習することができる。上記の理由から、本研究では、PointNet++を採用することとした。

### (3) 使用ネットワークの構成について

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含むネットワークを構築している。1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。サンプリング方法には FPS (Farthest Point Sampling)<sup>6)</sup>を用いて、入力点群から均等感覚に代表点となる点を選択する。次に2つ目のグルーピング層では、FPS によって選択されなかった点群に対して、FPS で選ばれた代表点群の中で最も近い代表点群のグループに振り分ける。PointNet++ではグルーピング手法として、一つの距離でグルーピングを行う SSG (Single Scale Grouping) と複数距離を考慮する MSG (Multi Scale Grouping)があるが、本研究では計算コストの低い SSG を採用した。これら二層と 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。

図-3 に示すように、PointNet++は入力データの情報の集約を行う特徴抽出箇所は、クラス分類およびセマンティックセグメンテーションモデルの双方で同一である。

## 4. 適用例

### (1) 解析対象：島根県隠岐郡知夫村地先

本研究の解析対象として、消波ブロックが点在する水深10m以浅の海域をとりあげる。また、分類および色付け対象として二種類の消波ブロックを取り上げる。水中点群データ取得後、点群処理ソフトを用いて、一定領域ごとに含まれる各ブロックの点群データ抽出した。抽出したブロックを図-4 に示し、使用するモデルとトレーニングデータ・テストデータの組み合わせを表-1 に示す。それぞれブロック A、ブロック B とし、分類モデルとセマンティックセグメンテーションモデルそれぞれに対し評価を行う。

### (2) トレーニングデータ・テストデータ

分類モデルにおけるテストデータには、データの取得




図-4 3DCAD モデルから作成した点群モデル

表-1 トレーニングデータおよびテストデータ

	トレーニングデータ	テストデータ
検出モデル	①未加工データ 各50種類	計測領域から 抽出した個別データ
	②加工データ 各50種類	ブロックA：115個 ブロックB：54個
セマンティック セグメンテーション モデル	加工したブロックデータ 同一空間上に24個配置した領域 データを20種類	計測領域から 抽出した領域データ ブロックA：3領域 ブロックB：1領域

領域から得た個別の点群モデルデータを用いる。一方、セマンティックセグメンテーションモデルにおけるテストデータには取得した領域データを直接使用している。

また本研究では、分類対象の消波ブロックが既製品であることから、設計図面に基づいた 3DCAD モデルを作成し、点群モデルに変換することで、トレーニングデータの作成を行う。作成した各ブロックのトレーニングデータの一例を図-4 左側に示す。各モデルを構成する総点数は約 3,000 点となっている。

分類モデルにおけるトレーニングデータには、図-4 左側に示す作成した個別の点群モデルを用いる他、水面から影や死角となる部分が欠損しているブロックデータを考慮し、元のトレーニングデータを一部切断することによって分類精度を高める工夫を施した。作成した点群データは図-4 右側に示すとおりである。

### (3) 解析結果

加工した点群モデルにおいても同数のモデルを用いることで、未加工のデータとの精度比較を行う。一方、セマンティックセグメンテーションモデルにおけるトレーニングデータには分類モデルにおいて精度の高かった個別のブロックデータを用いて、領域データを作成する。分類モデルの評価を表-2 に示すとともに、セマンティックセグメンテーションによる結果の一部を図-5 に示す。

### (4) 考察

分類モデルの結果から、加工したデータを用いることで、正解率および分類精度が 2 倍近く向上していることが確認できる。また、セマンティックセグメンテーションの結果においても、Mean-IoU 値を算出したところ 0.996 と非常に高い値を示しており、各ブロックに対して領域分類が行われていることが確認できる。このことから、3DCAD データから点群データ作成し、一部を切断する処理が有効であったと考えられる。

## 5. おわりに

本論文では、ASV といった無人ロボットによるマッピングデータの取得と点群深層学習による物体分類および判別を行った。PointNet++を用いることで自動分類とセマンティックセグメンテーションを実現した。また、本手法の有効性を検証するため、実際に計測された水中マッピングデータに PointNet++を適用することで、トレーニングデータに 3DCAD データから作成した点群データと一部を切断したデータを採用することにより、飛躍

表-2 分類モデルの混同行列による評価

未加工				加工							
データ		正解[個]		再現実		データ		正解[個]		再現実	
		ブロックA	ブロックB			ブロックA	ブロックB			ブロックA	ブロックB
予測 [個]	ブロックA	15 /115	100 /115	0.13		93 /115	22 /115	0.81			
	ブロックB	10 /54	44 /54	0.81		4 /54	50 /54	0.93			
適合率		0.60	0.31	F値		0.96	0.69	F値		0.85	
				0.46							




図-5 セマンティックセグメンテーション結果

的に分類性能が上昇することが確認された。

今後は、さらなる適用事例の増加と分類クラスの細分化および転移学習を用いた水中構造物の分類について検討を行う予定である。

### 参考文献

- 1) 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, pp.29-34, 2019.
- 2) Qi, C.R., Yi, L., Su, H. and Guibas, L.J.: PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space, *Advances in neural information processing systems*, pp. 5099-5108, 2017.
- 3) 浅田昭: マルチビームソナーによる海底地形の可視化, 日本音響学会誌, 第 10 号第 55 巻, pp. 717-722, 1999.
- 4) Maturana, C. and Scherer, S.: Voxnet: A 3d convolutional neural network for real-time object recognition, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 922-928, 2015.
- 5) 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.
- 6) Moenning, C. and Dodgson, N. A.: Fast Marching farthest point sampling for implicit surfaces and point clouds. *Computer Laboratory Technical Report University of Cambridge, UK*, No.565, 2003.