

テーマ番号	1EP44			
プロジェクト テーマ	和文	深層学習に基づく水中移動目標のモニタリングに関する研究	指導教員	長田 茂美 教授
	英文	Research on Monitoring of Underwater Movement Target Based on Deep Learning		
プロジェクト メンバー	4EP3-22 小島 尚之 (Naoyuki Kojima)			

Abstract Recently, important facilities (e.g. nuclear power plants) located near harbor have been exposed to threats over and under the water. Therefore, it is expected to realize a harbor monitoring system that can detect and classify threats using underwater acoustic technology. In our laboratory, we have constructed a harbor monitoring system that can automatically detect and classify acoustic data acquired by passive acoustic sensors into three types of threats (divers, underwater scooters with divers, and ships) using deep learning. In this study, we propose a harbor monitoring system that applies learning methods with weakly supervised learning and Between-class Learning as an attempt to further improve accuracy, and confirmed its usefulness by evaluation experiments. We also examined the applicability to ecological monitoring of underwater organisms as a new application of deep learning and underwater acoustics technologies of the harbor monitoring system that we have developed so far, and confirmed that this field could be a promising application field.

Keywords harbor surveillance, underwater threat detection, deep learning, offshore fish farming, underwater organism monitoring.

1. まえがき

近年、港湾に隣接する原子力発電所などの重要施設は、水上、水中からの脅威への対応が求められており、多様なセンサを用いて脅威を検出・分類できる港湾監視システムの実現が期待されている。当研究室では、港湾監視システムを実現するための研究開発の一環として、パッシブ音響センサにより取得した音響データを、深層学習を用いて、脅威となる水中移動目標（ダイバー、水中スクータ+ダイバー、船）3種類とそれ以外の環境雑音の計4種類のカテゴリに自動的に分類できる港湾監視システムを構築してきた^[1]。

本研究では、さらなる精度向上の試みとして、弱教師あり学習^[2]、BC learning (Between-class Learning)^[3]を用いた学習手法を提案し、港湾監視システムに適用・評価を行い、その有用性を確認した。また、これまで開発してきた港湾監視システムの深層学習技術や水中音響技術などの新たな展開として、水中生物の生態モニタリングへの応用検討も実施し、この分野が有望な応用分野になり得ることも確認できた。

本稿では、これらの港湾監視システムおよび水中生物の生態モニタリングに関する研究開発について述べる。

2. 港湾監視システムの概要

図1に、当研究室で開発してきた音響データから水中移動目標を検出・分類する港湾監視システム^[1]の概要を示す。まず、パッシブ音響センサから取得した音響データに対して、高速フーリエ変換(FFT, Fast Fourier Transform)を適用し、1秒間ごとの0.5~10kHz帯のスペクトログラムを生成する。次に、自己符号化器(AE, AutoEncoder)を用いて、分類に悪影響を与えるノイズをスペクトログラムから除去する。最後に、畳み込みニューラルネットワーク(CNN, Convolutional Neural Network)を用いて、4種類の水中移動目標を自動分類する。




図1 システムの概要
Fig. 1 Overview of the system.

3. 提案手法

港湾監視システムのさらなる分類精度向上を目指して、港湾

監視システムの分類器である CNN の弱教師あり学習および BC learning を用いた2つの学習手法を提案する。

3.1 手法 I: 弱教師あり学習の適用

弱教師あり学習を用いた提案手法 I は、以下の手順で、典型的な学習データ（スペクトログラムとカテゴリの組）を拡張し、CNN を訓練する。

Step.1: 使用可能な学習データセット TD_ava の中から、ダイバー、水中スクータ+ダイバー、船の3種類のカテゴリごとに、環境雑音の少ない典型的な特徴をもつデータとすべての環境雑音のデータを初期の学習データ TD_ini として抽出するとともに、TD_cnn にも格納する。

Step.2: TD_cnn を用いて、CNN を訓練する。

Step.3: TD_ava の学習データ（スペクトログラム）を学習済み CNN に入力し、出力として得られる確信度が高い（設定した閾値 Th 以上の）学習データを、そのカテゴリの典型的な学習データとして TD_cnn に追加する。追加されるデータがあれば、Step.2に戻り、なければ、終了する。

このようにして、提案手法 I は、3種類のカテゴリごとの確信度が高い典型的なデータとすべての環境雑音のデータを学習データとして用いて、分類器である CNN を訓練するものである。図2に、提案手法 I の概要を示す。




図2 手法 I: 弱教師あり学習の適用
Fig. 2 Method I based on weakly supervised learning.

3.2 手法 II: BC learning の適用

昨年度の研究^[1]では、UMAP^[4]というデータ分布の可視化手法を用いて、各カテゴリ間に類似したデータが存在することを確認するとともに、各カテゴリ間の決定境界を明確化する BC learning を適用することにより、分類精度の向上を試みた。提案手法 II は、弱教師あり学習を用いた提案手法 I によりカテゴリごとに抽出した確信度が高い典型的な学習データに BC learning を適用するものである。図3に、弱教師あり学習と BC learning とを組み合わせた提案手法 II の概要を示す。




図3 手法II : BC learning の適用
Fig. 3 Method II based on BC learning.

4. 評価実験

提案手法の有用性を確認するために、評価実験では、2014, 2017 年度に金沢工業大学穴水湾自然学苑近海で収集した合計 2037 組の音響データとそれに紐づけられた 4 種類のカテゴリの正解レベルからなるデータセットを用いた。このデータセットは、人間が聴いてもカテゴリを特定しづらい S/N 比が極めて悪いデータを除去し、再構築を行ったものである。

4.1 データセット

表 1 に、提案手法 I の評価実験で用いた学習データセット TD_ini, TD_ava, 確信度の閾値 Th を 0.9~0.1 に設定したときに最終的に生成された学習データセット TD_cnn_f の学習データ数と、テストデータセットのテストデータ数を示す。

表 1 各種データセットのデータ数
Table 1 Number of data in various datasets.

	ダイバー	水中スクータ+ダイバー	船	環境雑音	合計
TD_ava	981	76	98	585	1740
TD_ini	535	60	62	585	1242
Th = 0.9	845	62	87	585	1579
Th = 0.8	885	70	89	585	1629
Th = 0.75	888	70	89	585	1632
Th = 0.5	956	70	97	585	1708
Th = 0.1	974	76	98	585	1733
テストデータセット	77	53	48	119	297

4.2 実験および結果

提案手法 I の評価実験では、確信度の閾値 Th を 0.9~0.1 に設定したときの最終的に生成された学習データセット TD_cnn_f を用いて訓練した CNN の分類精度を評価した。図 4 に、閾値 Th を 0.9~0.1 に設定したときの TD_cnn_f で訓練した CNN と、TD_ava を用いて訓練した CNN の正解データ数を示す。この結果より、提案手法 I で生成した TD_cnn_f を用いて訓練した CNN は、より少ない学習データで、TD_ava で訓練した CNN と同程度の分類精度を達成でき、提案手法 I の有効性が確認できた。




図4 正解データ数 vs. 確信度の閾値 Th
Fig. 4 Number of correctly classified data vs. thresholds Th.

提案手法 II の評価実験では、提案手法 I で追加、生成される TD_cnn を、学習データが繰り返し追加されるごとに TD_cnn_1st, 2nd, ..., n-th と保存しておき、これらの学習データセットを用いて BC learning を適用した CNN の分類精度を評価した。図 5 に、TD_ava を用いて BC learning を適用した CNN の分類精度とともに、閾値 Th=0.8 の TD_cnn_n-th を用いて BC learning を適用した CNN の分類精度を示す。これは、環境雑音を除く 3 種類のカテゴリに対してのみ、




図5 TD_cnn_n-th を用いた BC learning による分類精度
Fig. 5 Classification accuracy by BC learning using TD_cnn.

BC learning を適用した場合の結果である。TD_cnn_7th では、TD_ava を用いた場合、すなわち、すべての学習データを用いて BC learning を適用した場合の正解率を超えており、提案手法 II の有用性が確認できた。

5. 水中生物の生態モニタリングへの応用

近年、海底に着目した沖合栽培漁業への期待が高まっており、光の少ない海底では、音響センサによる底魚などのモニタリング技術が必須となる。そこで、港湾監視システムの深層学習技術や水中音響技術の新たな展開として、水中生物の生態モニタリングへの応用可能性について検討した。

表 2 に、検討に用いた 4 種類の水中生物の鳴音データに FFT を適用して得た学習/テストデータ (1 秒間の 0.5~10kHz 帯のスペクトログラム) の数と、港湾監視システムをチューニングすることなく適用した場合の分類精度を示す。まだデータ数が少なく、環境雑音フリーのデータではあるものの、港湾システムの要素技術の新たな応用分野として有望であることが確認できた。

表 2 学習/テストデータ数と分類精度
Table 2 Number of data and classification accuracy.

	学習データ数	テストデータ数	分類精度
ホウボウ	14	14	92. 9%
イセエビ	10	10	70. 0%
トラフグ	10	10	100. 0%
ウツリガキ	10	10	100. 0%

6. むすび

本研究では、港湾監視システムのさらなる精度向上の試みとして、弱教師あり学習、BC learning を用いた学習手法を提案し、港湾監視システムに適用、評価を行い、その有用性を確認した。また、港湾監視システムの要素技術の新たな展開として、水中生物の生態モニタリングへの応用検討も実施し、この分野が有望な応用分野になり得ることも確認できた。今後はさらなる精度向上を図っていく予定である。最後に、多大なるご支援をいただいている日本電気株式会社の関係各位に感謝いたします。

参考文献

- [1] 八野司, 加古著人, 小倉綾, “水中音響技術を利用した港湾監視システムに関する研究,” 令和元年度プロジェクトデザインIII 公開発表審査会予稿集, 1EP184, 2020.
- [2] 杉山将, “弱教師付き機械学習の新展開,” PT1, 第 26 回画像センシングシンポジウム(SSII2020), 2020.
- [3] Yuji Tokozume, Yoshitaka Ushiku, Tatsuya Harada, “Between-Class Learning for Image Classification,” Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.5486-5494, 2018.
- [4] Leland McInnes, John Healy, James Melville, “UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction,” arXiv:1802.03426, 2018.