テーマ番号	1EP184		
プロジェクトテーマ	和文	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	指導教員	長田 茂美 教授
	英文	Research on the Harbor Monitoring System Using Underwater Acoustic Technology		
プロジェクトメンバー	4EP3-60 八野 司 (Tsukasa Yano)　4EP2-13 加古 著人 (Akihito Kako) 4EP1-11 小倉 綾 (Ryo Ogura)			

Abstract Recently, import facilities (e.g. nuclear power plants) located near harbors have been exposed to threats over and under the water. Therefore, the development of harbor surveillance system that can detect and classify threats is expected. Our lab team the development has constructed a system that can automatically detect and classify three types of underwater threats divers, underwater scooters with divers, or ships, using Convolutional Neural Network (CNN) and AutoEncoder (AE). To further increase the classification accuracy, the current research improved the processing flow of AE and CNN, and the structure of CNN. Also, the data used in this research is difficult to obtain and insufficient, we have extended the number of data. The results confirmed the usefulness of three approaches: improvement of the processing flow of AE and CNN, enhancement of the CNN structure, and augmentation of the data.

Keywords harbor surveillance, underwater threat detection, passive acoustic sensor, spectrogram, deep learning.

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 種とそれ以外の環境雑音の計 4 種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．

本研究では，ノイズ除去処理方法の改良，水中移動目標の分類に用いる分類器の構造の改良，学習手法の改良を行い，それらに対応する 3 つの提案手法の評価を実施した．

2. システム概要

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，水中移動目標を自動で分類する．

3. 提案手法

港湾監視システムの精度向上を目指して，ノイズ除去処理，CNN の構造，学習手法の 3 つの改良手法を提案する．

3.1 ノイズ除去処理の改良（提案手法 I）

図 2 に，従来および提案手法 I の AE と CNN の処理過程を示す．従来は，AE でノイズ除去，CNN でスペクトログラムの分類を個別に処理していたため，AE でノイズ除去する過程において，各カテゴリの特徴が付加あるいは削除されることがあり，これが誤認識の要因となっていた．

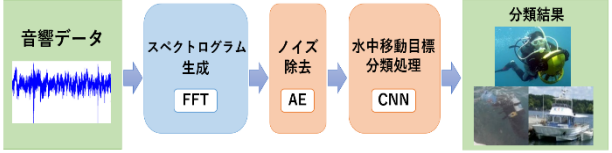

図1 システムの概要
Fig. 1 Overview of the system.

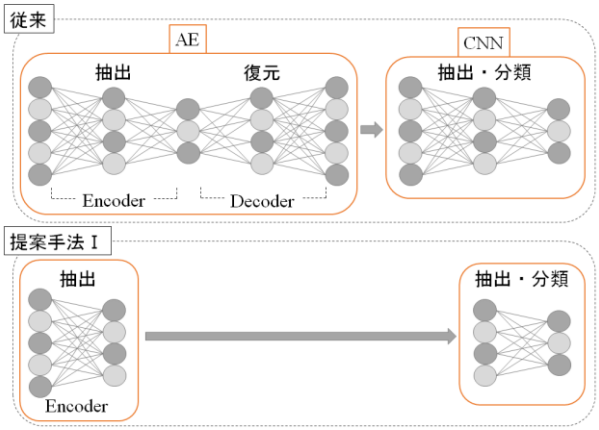

図 2 AE と CNN の処理過程
Fig. 2 The process of AE and CNN.

この AE の問題を解決するため，システムで用いられている CNN を AE の Encoder の出力に対応できる CNN に改良する．提案手法 I では，Encoder が抽出した特徴を直接分類することで，水中移動目標の特徴を効果的に取り出すことができ，分類精度の向上が期待できると考える．

3.2 CNN の構造の改良（提案手法 II）

図 3 に，従来と提案手法 II の CNN の構造を示す．当研究室で使用する音響データには，異なるカテゴリで類似したデータが多く存在する．従来の CNN では，特徴を圧縮･抽出する際にそれらの差違が消失するのを防ぐため，max-pooling 層を使用していなかった．しかし，特徴が抽象化された深い層であれば，max-pooling 層を使用するこ

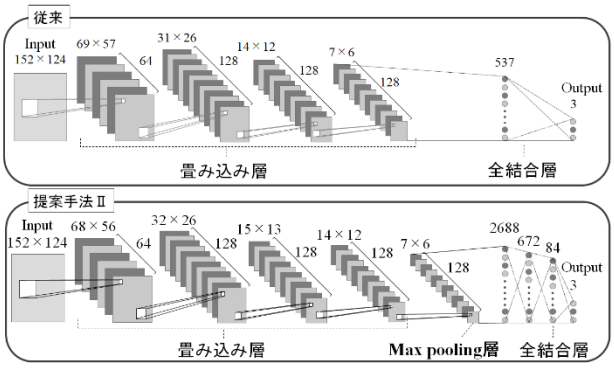

図 3 CNN の構造
Fig. 3 The structure of CNN.

とができるのではないかと考え，図 3 に示すような形で，max-pooling 層を追加する．また，全結合層の層間のユニット数（特徴の次元数）の急激な変化による特徴の消失を防ぐため，全結合層に 2 層の中間層を追加する．

3.3 学習手法の改良（提案手法Ⅲ）

従来の誤分類の原因を追究するために，UMAP[2]と呼ばれるデータの類似性を可視化する手法を用いて，データセットの分析を行った．その結果，各カテゴリのデータの分布の間にはかなりの重なりが存在し，各カテゴリを区分する境界部分が曖昧であるため，そのことが CNN によるデータの分類を困難にしていることが確認できた．

この問題を解決するために，各カテゴリ間の決定境界をより明確化する学習手法である between-class learning(BC learning)[3]を用いることを考える．図 4 に，BC learning によるダイバーと環境雑音とのデータの合成処理例を示す．BC learning は，学習データを基に，異なるカテゴリに属するデータをランダムな比率で合成し，それらのカテゴリ間の特徴が混ざりあった新たなデータを作り出す．したがって，BC learning を適用すれば，各カテゴリ間の決定境界付近に位置する学習データを生成できる．そのため，それらの学習データを CNN に学習させることで，分類を困難にしているカテゴリ間の決定境界を明確化することができ，分類精度の向上が期待できる．

こうした考えから，この BC learning を従来の学習過程に適用した提案手法 III を提案する．

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 2118 組の音響データとそれに紐付けられた 4 種のカテゴリの正解ラベルからなるデータセットを用いた．表 1 に，学習データ数およびテストデータ数を示す．評価指標として，次式(1)で定義される再現率を用いた．

再現率 ＝(分類結果が A で正解が A であるデータ数)
/ (正解が A であるデータ数)　　(1)

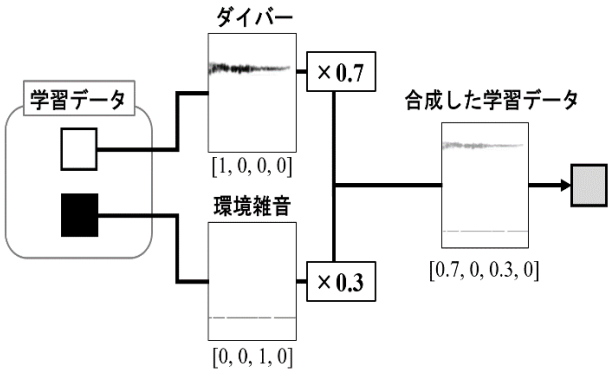

図 4 BC learning を用いたデータ合成処理
Fig.4 The process of the data composition by BC learning.

表1 学習データ数およびテストデータ数
Table 1 The number of training and test data.

	学習データ数	テストデータ数
ダイバー	981	82
水中スクータ+ダイバー	634	53
船	76	49
環境雑音	98	145

4.1 評価結果

表 2 に，従来と提案手法 I, II, III の評価実験結果を示す．提案手法 I の評価実験では，AE の Decoder による特徴の付加あるいは消失が誤分類の原因であると考えていたが，Encoder の出力を取り出し，CNN に入力することによって，Decoder による情報の付加あるいは消失を防ぎ，水中移動目標の分類精度を向上させることができた．さらなる精度向上のためには，提案手法 II で検討したように，CNN の構造の深層化や max-pooling 層の追加など，CNN の構造も含めた詳細な検討が必要である．

提案手法 II の評価実験では，水中移動目標の特徴を際立たせたまま圧縮する構造を持つ max-pooling 層を用いることで，従来よりも本質的な特徴を捉えることが可能となり，水中移動目標の分類精度が向上したものと考えられる．引き続き，体系立った評価実験を行い，CNN に限らず，より最適な分類器の構造を探求する必要がある．

提案手法 III の評価実験では，BC learning によって水中移動目標のカテゴリ間の決定境界がより明確化され，環境雑音を除く水中移動目標のカテゴリの分類精度については向上させることができた．しかしながら，環境雑音の特徴は，水中移動目標のカテゴリが存在するしないに拘らず，全カテゴリにまたがって存在するものあり，決定境界を明確化する BC learning の適用により，環境雑音については，誤分類を誘発してしまう結果になったものと考えられる．環境雑音は，1 つのカテゴリを形成するものではなく，従来は“棄却”として扱ってきたが，典型的な複数の分類カテゴリとみなして BC learning を適用してみるなど，環境雑音への BC learning のより有効な適用法も検討していく必要もあろう．

本研究では，3 つの提案手法の各々については，評価実験により，それらの有用性を確認することができた．今後は，これら 3 つの提案手法を統合的に活用することによって，より高精度な分類能力をもつ港湾監視システムの実現を目指したい．

表2 評価実験結果
Table 2 Result of evaluation experiment.

	ダイバー	水中スクータ+ダイバー	船	環境雑音
従来システム	86.6%	96.2%	91.8%	95.9%
提案手法 I	91.5%	98.1%	89.8%	95.9%
提案手法 II	89.0%	96.2%	95.9%	93.8%
提案手法III	92.7%	98.1%	98.0%	80.0%

5. むすび

本研究では，これまで開発してきた港湾監視システムに，3 つの提案手法を適用し，実音響データを用いた評価実験により，その有用性を確認した．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，多大なるご支援を頂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] 大島拓実，上木健之祐，“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”，平成 30 年度プロジェクトデザインIII公開発表審査会予稿集，EP170，2019.

[2] Leland Mclnnes，Jhon Healy，James Melville，“UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction,” arXiv:1802.03426, 2018.

[3] Yuji Tokozume，Yoshitaka Ushiku，Tatsuya Harada，“UMAP Between-Class Learning for Image Classification,” The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 5486-5494, 2018.