

深層学習による海底画像からのアワビの自動認識手法の開発

綾田 アデルジャン* 松本 有記雄† 萩原 義裕‡

秋田公立美術大学複合芸術専攻* 国立研究開発法人水産研究・教育機構†

岩手大学理工学部‡

1. はじめに

水産業において重要なウェイトを占める磯根資源の漁獲量は海況変動などの影響による減少傾向が続いており、磯根資源の持続的な利用のため、多くの地域では毎年潜水調査による資源現状や生育状況などについての調査が実施されている。その調査結果は資源回復対策の重要な参考になっており、漁獲可能な量の提示などにも利用される。磯根資源の調査において、潜水調査は最も一般的な方法であり、図1のようにあらかじめ設定した調査点で、生息状況確認、防水カメラにより海底状況の記録などが行われる。しかし、潜水調査には多大な時間と労働を伴うことや、高齢化や後継者不足などによる潜水土不足の問題も挙げられている。そのため、資源調査において最新技術をフル活用し、低負荷かつ持続可能な資源管理のための仕組みが求められている。

本研究は画像認識をベースにした磯根資源の資源管理システムの提案を目的とする。本稿では、ウニなどほかの磯根資源に比べ発見されにくい生態を持つアワビを事例対象に、畳み込みニューラルネットワーク(CNN)に基づく物体検出手法の一つである YOLOv4 [1]を用いたアワビの

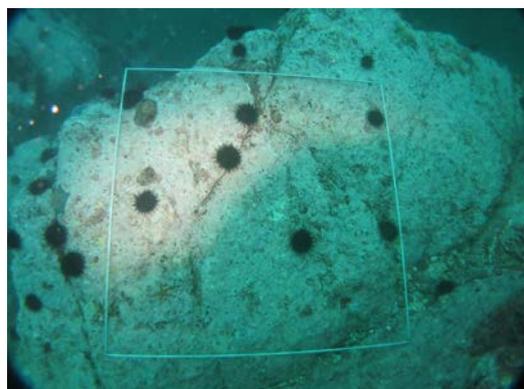


図1. 潜水調査の様子

認識方法の提案およびその実験結果について報告する。

2. 認識手法

2.1 認識モデル

近年, CNN をベースにした様々な深層学習手法が提案され, 物体認識において, 高精度な検出が実現されている. 代表的な手法として ResNet [2], Faster R-CNN [3], YOLO などがある. この中の YOLO (You Only Look Once)は計算負荷が少なく認識精度が高いアルゴリズムであり, 物体認識の分野においても, 主流検出器として幅広く用いられている. YOLO にはオリジナルの YOLO[4]をベースにしてさらに処理速度や検出精度を改善した幾つのアルゴリズムが提案されており, それらの改良手法も含めて YOLO と呼ぶことも多い. YOLOv4 は YOLO を改良した YOLOv3[5]のネットワークアーキテクチャをさらに改良し, 並行計算による高精度で物体検出が可能にしている.

YOLOv4 はバックボーン, ネックとヘッドと言う 3 つの部分から構成されている. バックボーンでは CSPDarknet-53 が利用され, 入力画像から特徴量抽出を行い, ネックでは SPP, PAN を利用してバックボーンから受けた特徴マップから特徴を選出する. 最後のヘッドでは, YOLOv3 を同じアーキテクチャを用いて, バウンディングボックスとクラス分類を行う.

本研究では, YOLOv4 を用いてアワビ認識モデルを構築し, 海底画像からアワビを検出する手法を提案する.

2.2 データセット

本研究でアワビの学習モデルを作成用に用いるアワビのデータセットは 1898 枚の画像から構成されており, このうち 1690 枚の画像は潜水調査の時撮影された海底画像から集められており, 残りの 208 枚の画像は船に取り付けた防水カメラで海底を撮影した画像である. 潜水調査による画像のサイズはバラバラであるが, 船に取り付けた防水カメラで撮影した画像のサイズは 1024 × 768 である. 入力画像のサイズを 800 × 600 に統一し, フォーマットを JPEG にしてから各画像

Deep Learning-based automatic abalone recognition from underwater image

* Adiljan Ayata, Akita University of Art

† Yukio Matsumoto, Japan Fisheries Research and Education Agency

‡ Yoshihiro Hagihara, Iwate University

に対し, labelimg [6]によりラベル付けしてアノテーションを行い, 学習データセットを作成した.

3. 実験および考察

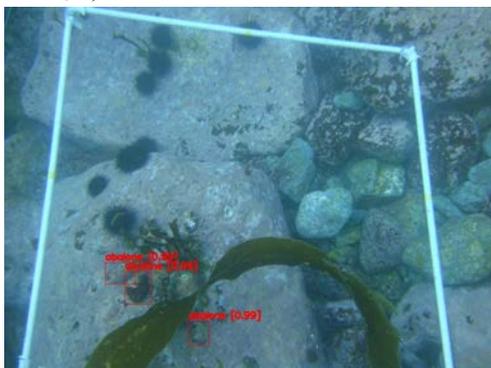
3.1 実験内容

YOLOv4 では入力サイズを 32 の倍数の正方形に設定できるが, 本研究では, オリジナルの 416 pixel × 416 pixel にした. また, 今回はアワビのみ検出するため, 1 クラスに対応する畳み込み層のフィルタ数を 18 にした.

総数 1898 枚あるデータセットのうち, 1708 枚を学習モデル作成用に, 残りの 190 枚をテスト用に分割した. 学習には YOLOv4 が公開されているサイトからダウンロードした学習済みのウェイト[7]を使用し, 移転学習によってアワビを認識するモデルを構築した. 実験環境は OS が Window 10, GPU は GeForce TITAN RTX, CUDA 10.1 を使用した.

3.2 結果および考察

学習が完了したモデルの性能を確認するため, テスト用画像に対してアワビの検出を行った. その実験結果の一例を図 2 に示す. 検証結果, 集めた潜水調査による海底画像からアワビを検出することができたが, 形状がアワビに似ている石やウニなども検出されたケースもあった. このことは, 船に取り付けたカメラの画像から検出を実施した時, より多く確認できた. その一例を図 3 に示す.



(a)



(b)

図 2. テスト用画像からのアワビ検出結果

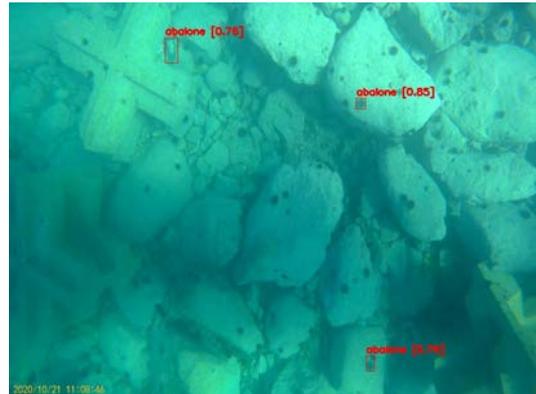


図 3. 船に取り付けたカメラ画像からの検出

5. おわりに

本稿では, 畳み込みニューラルネットワークベースのワンステージ物体検出アルゴリズムである YOLO v4 を用いて海底画像からアワビの検出手法を検討した. 訓練に使用したデータの中に資源調査のとき撮影したアワビ画像の枚数が多かったため, アワビが大きく映った画像から精度よくアワビを検出することができたが, 船に取り付けたカメラで撮影した画像から高い精度での検出が得られなかった. しかし, 学習用の画像を増やすことやデータの拡張手法を適用することでアワビ検出精度の向上が期待できた.

今後の課題として, 深層学習の性能を発揮させるためのデータセットの補充, 認識率の向上, 小型 PC などの処理性能が高くないデバイスでもアワビの認識が可能な学習モデルの検討などが挙げられる.

謝辞

本研究は JSPS 科研費 19K20298 の助成を受けたものです.

参考文献

- [1] Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M., "YOLOv4: Optimal Speed and Accuracy of Object Detection", arXiv preprint arXiv:2004.10934, 2020
- [2] He, K., Zhang, X., Ren, S., & Sun, J., "Deep residual learning for image recognition", Proc. of the IEEE conference on CVPR, pp. 770-778, 2016
- [3] Ren, S., He, K., Girshick, R., & Sun, J., "Faster R-CNN: Towards real-time object detection with region proposal networks", IEEE transactions on pattern analysis and machine intelligence, 39(6), pp.1137-1149, 2016
- [4] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A., "You only look once: Unified, real-time object detection", Proc. of the IEEE conference on CVPR, pp.779-788, 2016.
- [5] Redmon, J. and Farhadi, A.: YOLOv3: An Incremental Improvement, arXiv preprint arXiv:1804.02767, 2018.
- [6] Tzutalin, LabelImg, Git code: <https://github.com/tzutalin/labelImg>, (Accessed: 7-Jan-2021)
- [7] Bochkovskiy, A., "Alexeyab/darknet", <https://github.com/AlexeyAB/darknet>, (Accessed: 7-Jan-2021)