

水中映像からのマグロ成魚の領域抽出と尾数推定

竹長 慎太郎[†] 波部 斉[†] 阿部 孝司[†] 井口 信和[†]近畿大学理工学部[†]

1. はじめに

水産養殖の生産性を向上させるためには、養殖魚の状況を観察し、適切な養殖環境になるように調整することが必要になる。養殖魚の成長状況を把握する上で基本となるのは尾数の把握である。特に、クロマグロは外部からの刺激に敏感であるため、その養殖においてはクロマグロに刺激を与えない尾数計測が求められている。しかし、多数の魚が洋上の生簀の中で遊泳している場合に、その尾数を非侵襲・非接触で把握することは困難である。

本稿では、ダイバーが生簀の下から撮影した水中映像から遊泳しているクロマグロ成魚の領域抽出・尾数推定を行う。水中映像には波や太陽の光といった外的要因を含んでいるため単純な映像解析により尾数推定を行うことは難しい。本研究では、まずセグメンテーションを用いてクロマグロ成魚に相当する領域（以下、成魚領域）とそれ以外の領域の識別を行う。次に得られた結果に対し、ラベリング処理を行い連結領域に何匹いるかを畳み込みニューラルネットワーク(CNN)を用いて推定することで水中映像中のクロマグロ成魚の尾数推定を実現する。

先行研究として、個体数計数システムの開発の研究が行われている[1]。この研究ではPTV解析によって魚の動きを捉えて尾数を推定しているが、外的要因の影響を強く受けることが弱点となっている。そこで、本研究では深層学習を用いて魚の見え方をモデル化して外的要因の影響を受けにくい尾数推定を行う。

2. 提案手法の概要

本研究では、領域抽出を高速、省メモリ行えるSegNet[2]を元にして今回の環境に適した領域抽出を行う。得られた結果に対してラベリング処理を行い各々の連結領域に何匹いるかCNNを用いて推定し、映像中の尾数推定を行う手法を提案する。Badrinarayananらが[2]で使用した映像に比べ分類するクラス数が少ないため、SegNetを元に構造を簡略化したネットワークを用いる。領域抽出から得られた結果に対してラベリング処理を行いラベルごとに矩形で切り出す。切り出された魚の向きは様々であるため、主成分分析(PCA)を用いて魚の向きを統一し、画像をリサイズする。学習データが似ており過学習に繋がるため、用いるCNNの構造は可能な限り単純なものとする。

3. 深層学習を用いた領域抽出

提案手法の領域抽出の部分の流れを図1に示す。領域抽出の提案手法では、成魚領域の抽出を行いたい画像を入力画像(図1左)として入力し分割する。あらかじめ学習したモデルを使い入力画像に対して成魚領域の抽出

Region Extraction and Population Estimation of Large Tuna from Underwater Images

[†]Kindai University Faculty of Science and Engineering

を行う(図1右)。領域抽出を行う際、少量のデータ数で行うために、16, 25, 36等分に分割しデータ数を増やし利用する。分割したデータの画像サイズは異なるため、画像サイズを解像度360×480にリサイズする。リサイズした画像を学習データに80%、テストデータに20%使用する。

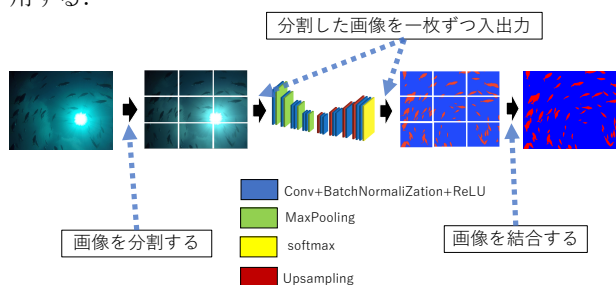


図1. 提案手法の流れ(領域抽出)

4. 深層学習を用いた尾数推定

尾数推定の部分の流れを図2に示す。提案手法では、3節の手法で得た二値化画像に対してラベリング処理を行い連結画像ごとにそれを囲む最小の矩形領域を切り出す。切り出した画像にPCAを適用して魚の向きと画像サイズを統一したものをCNNの入力画像とする。これと連結領域に存在するマグロの尾数を対してCNNを学習する。尾数推定で使用したCNNの構造を図3に示す。

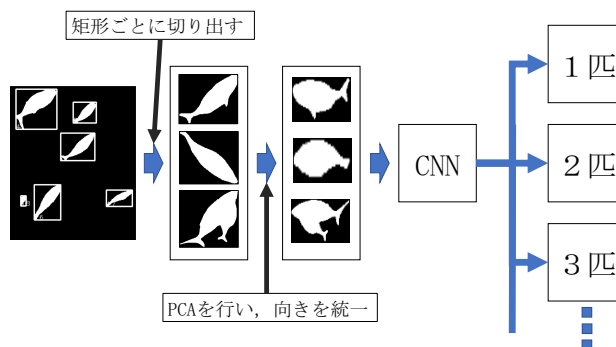


図2. 提案手法の流れ(尾数推定)




図3. CNNのネットワーク構造(尾数推定)

5. 実験

本章では、クロマグロ成魚の領域抽出と尾数推定を行う実験の手法の結果について述べる。

5.1 用いる成魚のデータ

用いる画像データは、近畿大学水産研究所奄美実験場においてダイバーが生簀の中に潜り下から遊泳しているクロマグロ成魚を撮影した映像から40枚切り出したものである(解像度2028 × 2704)。領域抽出の評価映像は同じ環境下で撮影されたものを用いる。尾数推定の際に使用する画像は領域抽出で得られた結果を使用する。学習データは、得られた結果の画像に対してラベリング処理を行い、ラベルごとの矩形で切り出し、PCAを用いて魚の向きを統一し画像をリサイズしアノテーションを行う。学習データは1匹、2匹、3匹それぞれ100枚、100枚、75枚とする。計275枚を学習データ、テストデータとして220枚、55枚にわけて使用する。評価映像には、学習に使用していない箇所から一枚選び、尾数計測の評価を行う。尾数推定の際には画像の端で一部が隠れている個体は対象としない。

5.2 評価方法

領域抽出は、あらかじめ人手によって正解領域に色を塗った画像を用意し、領域検出された画像と画素単位で比較し精度を算出する。評価値として、再現率、適合率、それらの調和平均であるF値を用いる。

尾数推定は、学習に使用していない映像から1枚選び、人手で対象となる矩形内に何匹いるかをカウントした尾数と、CNNによる尾数推定結果を比較し精度評価を行う。

5.3 実験結果

領域抽出の入力画像を図4左に示す。実験の出力結果を図4右に示す。領域抽出の実験結果の精度を表1に示す。実験結果(図4右、表1)を見ると、太陽の光や影、波といった外的要因があっても高い精度で成魚領域を抽出できていることがわかる。

尾数推定の結果は計測の対象となる矩形と誤推定の例を図5に示す。矩形内にいた尾数の合計は62匹であり、CNNにより検出された尾数は63匹であった。対象となる矩形51個である。各々の矩形に対しての尾数推定の結果とアノテーションの比較を行い、誤推定した矩形は、7個であり概ね尾数推定できていることがわかる。誤推定した矩形に着目すると、人目でも間違えるような映像である。全体的に学習データが十分に準備出来なかった為、誤推定していると考えられる。今回、4匹以上のデータは非常に少なかった為尾数推定できなかった。そのため、評価映像には3匹までで尾数推定を行える映像を選んでいる。



実験の入力画像 実験の出力画像

図4. 領域抽出の入力・出力画像

表1. 領域抽出の実験結果の精度

Precision	Recall	F-measure
94.10%	89.03%	91.49%

	正解値	推定結果
	2匹	3匹
	2匹	3匹
	3匹	2匹
	2匹	1匹

図5. 計測対象となる矩形と誤推定の例

6. まとめ

本研究では遊泳しているマグロの領域抽出、尾数推定を行う手法を提案した。検出する際に少量の学習データで外的要因を考慮し高い精度で領域抽出を行い、期待通りの精度が得られた。尾数推定も概ねできているが4匹以上は学習データが確保できず尾数推定を行うことができなかった。画像の端で一部が隠れている個体を考慮できていないという問題も残っている。

今後の課題として、尾数推定の精度を向上するために十分な学習データを確保する方法として擬似的に複数匹のデータを作成することが考えられる。また、画面の端で一部が隠れている魚などに対応するために時系列データの利用などが考えられる。

謝辞

本研究を行う上で貴重なご意見を頂戴し、映像取得にご協力いただいた近畿大学水産研究所の升間主計所長、近畿大学水産養殖種苗センターの岡田貴彦センター長、ならびに奄美実験場の皆様に御礼を申し上げる。また、本研究の一部はJSPS科研費JP17H05981の助成を受けて行った。

参考文献

- [1]. 高木 他, 画像解析を用いた非接触型養殖魚計測システムの開発, 水産工学 Vol.54 No.3, pp.209~213, 2018
- [2]. V.Badrinarayanan et al., "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation." PAMI, 2017
- [3]. L.Yann et al., "IEEE", Gradient-Based Learning Applied to Document Recognition, Vol. 86, No. 11, pp. 2278-2324, 1998.