

セマンティックセグメンテーションを用いた藻場領域の検出

Detection of seaweed area using semantic segmentation

○米内 一樹*, 萩原 義裕*, 田村 尚司*, 綾田 アデルジャン**
○Yonai Kazuki*, Hagihara Yoshihiro*, Tamura Naoshi*, Ayata Adiljan**

*岩手大学, **秋田県産業技術センター
*Iwate University, **Akita Industrial Technology Center

キーワード: 機械学習(machine learning), 画像認識(Image Recognition),
セマンティックセグメンテーション(Semantic Segmentation), 磯焼け(rocky-shore denudation)

連絡先: 〒020-8551 岩手県盛岡市上田 4-3-5 岩手大学大学院 総合科学研究科 理工学専攻 知能情報コース 萩原研究室 米内一樹, [Tel: 019-621-6400](tel:019-621-6400), [E-mail: g0321181@iwate-u.ac.jp](mailto:g0321181@iwate-u.ac.jp)

1. はじめに

沿岸地域の環境問題として「磯焼け」という現象がある。磯焼けは、大型の海藻の大部分が沿岸の一部で枯れてしまいウニやアワビなどの漁獲量が激減する問題である。またその原因は、自然環境の変化や人間活動の影響、海藻を食べる動物の影響等複数の要因が考えられており、早期に検出することで詳細な調査¹⁾及び対策も可能である²⁾。この現象を原因に関わらず検出する為の要素として藻場の面積の変化に注目する。

本研究では地域に関わらずこの問題をより簡易的に検出する為に、ドローンで撮影した画像に対してセマンティックセグメンテーションを用いて画像内の藻場の領域を分割・検出するという手法を提案する。

2. 提案手法

画像をピクセル単位でクラス分類するセマンティックセグメンテーションを用いる。また、学習の過程で畳み込みを行う際、特徴量マップを保持する処理を含むモデルである、U-net を用いることで特徴の位置情報を補完し、より詳細に領域が推定されることが期待される。また、本手法で使用する

モデルではセマンティックセグメンテーションにおけるアップサンプリング時に使う手法として Transposed Convolution を使用しており、他の学習モデルで使われる Pooling Indices 等と比較して精度の面で優れた結果が期待される。

2.1 学習モデル

本研究で用いる U-net は全層畳み込みネットワーク(Fully Convolution Network) の 1 種類であり、ダウンサンプリングの際に出力された特徴マップをアップサンプリング時に利用することで、より精度の高い、ピクセル単位での分類を行えるといった特徴を持つ³⁾。

3 クラスに分類するため、誤差関数は Softmax Cross Entropy を使用し、各関数の定義について Softmax は式(1)、Cross Entropy は式(2)で表される。

$$S(y_i) = \frac{e_i^y}{\sum_j e_j^y} \quad (1)$$

j : 1 からクラス数までの値をとる変数。

i : j の範囲内である特定のクラスを示す変数。

$$H(p, q) = - \sum_x p(x) \log(q(x)) \quad (2)$$

p を真の分布, q を推定分布とする.

2.2 FCN (Fully Convolution Networks)

FCN は, 大規模なデータから得られる階層的な画像特徴群を捉える Convolutional Neural Networks(以下 CNN) を画素毎のクラス識別結果を推定することを目的に, 設計を引き継ぎつつ改良したものである. 具体的には画像の特徴の位置情報が失われないように, CNNの全結合層を畳み込み層に変更したものである. また, 畳み込み層における処理は式(3)で表される.

$$a_{ij}^{(k)} = \sum_{s=0}^{m-1} \sum_{t=0}^{n-1} w_{st}^{(k)} x_{(i+s)(j+t)} + b^{(k)} \quad (3)$$

$s \times t$ のカーネル w (k 枚)を用いて

$i \times j$ の特徴マップ a (k 枚)を求める畳み込み演算.

3. 実験

3.1 実験概要

用意したデータセットに対し, 提案手法の項で述べた手法およびモデルを用いてセマンティックセグメンテーションを行った. データ数は 169 枚を学習用データ, 48 枚を評価用データとした. 撮影時の気候やそれに伴う水面の反射によって画像の質感が変化するため, 本実験では今後のデータ増加時を考慮して現在のデータのみを意識したパラメータ調整等を行わずに学習, 評価を行った. なお, 学習におけるバッチサイズは 10, エポック数は 50 として実験を行った.

3.2 データセット

ドローンを用いて上空から撮影した海上および海岸の画像を 128×128 にトリミングしたものを学習用及び評価用データとし, 以上を「藻」「海」「陸地」の 3 クラスに塗り分けをした画像を正解データとした. 各データの一例について学習用及び評価用データを Fig. 1, ラベル付けした正解データを Fig. 2 として以下に示す.

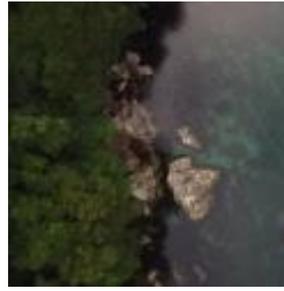


Fig. 1: 学習用画像

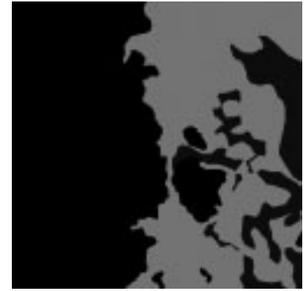
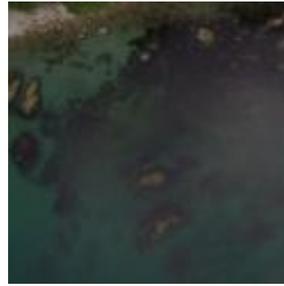
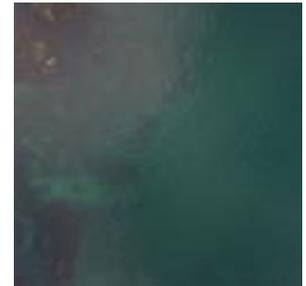


Fig. 2: 正解画像



(a)

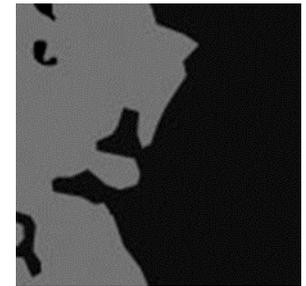


(b)

Fig. 3: 入力画像



(a)



(b)

Fig. 4: 正解画像



(a)



(b)

Fig. 5: 推論結果画像

3.3 実験結果

画像における藻場領域の鮮明さによって、領域分割の精度にも差が生じており、全体としての精度とともに画像ごとの精度の差も課題となる結果となった。

実験結果の一部を、一部検出できた例を(a)、検出の精度が不十分だった例を(b)として、入力画像を Fig. 3, 正解画像を Fig. 4, 推論を行った結果について藻場を斜線部とした出力画像を Fig. 5 として順に示す。

3.4 考察

実験の結果から画像毎の気候や海面の透過度等による藻場の視認性によって出力の結果に差が生じていることが確認できる。データによっては人間による目視でも画像からの判別が困難なものもあった為、評価時の精度だけではなく学習時にも悪影響を与えていた可能性がある。磯焼けやその回復における藻場面積の推移は時間をかけて進み³⁾、調査用の撮影の期間に余裕を持てることから、気象条件や海面の反射などを含めた藻場の視認性について、おおむね同一の環境条件下での撮影が可能かつ有効であると考えられる。

そのため、上記したような藻場領域が曖昧な画像を間引き、撮影時の気象条件を限定することが効果的であると考え。また、単純にデータの量を増やすことでの精度改善も期待できる。その為今後は、画像の選定を含めてデータセットを再度作成し、基準となる評価関数を定めた上で、アノテーション方法及び学習モデルの二要素による組み合わせと精度の関係性を求めていくことで、より詳細な考察とともに認識精度・実用性の向上を目指す。

4. おわりに

以上の内容から、研究背景にあたる磯焼けという問題を解決するような有効性は本実験終了時点の精度では認められなかった。しかし、画像によっては今後の改善により、有効性を期待できるものが見られた。また、精度の低下や画像ごとの差については今後は前項で述べたような手法の改善方法を方針とし、実験と結果に基づいた考察を繰り返すことで、藻場領域の検出精度とともに、最終目標である磯焼けの早期検出に向けての有効性も意識した、システム全体としての質を向上させていきたい。

参考文献

- 1) 浦 賢二郎, 「長崎県藻場回復ビジョンの概要と技術的課題」, 水産工学 Fisheries Engineering Vol. 55 No.1, pp.77-82, 2018
- 2) 藤田 大介, 「磯焼け」, 日本藻類学会創立 50 周年記念出版 「21 世紀初頭の藻学の現況」, 2002
- 3) Olaf Ronneberger, Philipp Fischer, and Thomas Brox, 「U-Net: Convolutional Networks for Biomedical Image Segmentation」, Lecture Notes in Computer Science, 2015