ローカルリモートセンシングによるアマモ場モニタリング手法の開発 ー機械学習によるアマモ場判別手法の有用性の検証ー

金沢工業大学 学生会員 ○岸本健一
金沢工業大学 正会員 有田 守

1. はじめに

アマモ場は沿岸域の生態系を支える重要な海草である。アマモ場の造成には成長を阻害する環境要因の究明が必要である。水質、光量などの要因のほかに生育状況を判断するための分布調査が行われる。現状の分布調査は潜水士によるコドラード調査や、航空写真などを用いたものがあるが、広域な藻場分布の調査に時間やコスト人員が必要になるなどの問題が挙げられる。

例えば大前ら(2008)は、分光カメラを用いてアマモなどの分光特性について研究しており、アマモ及びアオサ、ヒジキの植生について分光特性を調査した結果、3つの植生の分光形状はほぼ同じであることを示しており、空間的に分布した植生群を判別する際に閾値での領域抽出は空間的な反射強度の違いから困難であることを示している。澤井ら(2017)はこの問題について空撮画像に初期輪郭を与え、設定した輪郭の中心部に狭まっていく輪郭の輝度勾配の中で、ある領域から他の領域に変化する際の輝度変化から領域を定める領域ベースの Snake 法を用いたアマモ場領域抽出に関する研究を行っており、ガウシアンフィルタにより空撮画像を処理することで、領域抽出精度の向上と短時間での藻場領域の抽出の検討を行った。その結果、88~90%の精度で藻場を抽出することが可能となったが、領域抽出した藻場の植生が何であるか判別することはできない。そこで本研究は、抽出したアマモ場の分類判別の手法として低コストかつ継続的な分布調査ツールとなる機械学習を用いた空撮画像からのオートマチックな藻場分類手法の確立を目的とする。これにより、アマモ場の造成や海岸構造物の建設による藻場への環境影響評価のための分布調査において、低コストかつ短時間で汎用性のある分布調査が可能になれば、継続的なアマモ場のモニタリングを行うための調査手法の一つとして、沿岸域の環境保全に役立つ。

2. 解析方法

調査対象地としてアマモ、コアマモ、ホンダワラの自生が確認されている石川県七尾市能登島のそわじ浦海岸を対象として、無人飛行機を用いて高度 150m で空撮画像を撮影した。使用する機械学習手法は、CNN(畳み込みニューラルネットワーク)を用いる。図-1に、CNNの構成を示す。

図-1. CNNの構成

CNNは特微量抽出を自動的に行える機械学習手法であるため、画像認識に用いられている。畳み込み層とプーリング層が特微量抽出の役割を、続く全結合層以降で分類結果を計算し、入力データの教師信号との誤差から学習の更新を行い分類精度の向上をする。CNNの分類で重要なことは、ハイパーパラメータの設定である。ハイパーパラメータは、特微量の抽出が自動的に行われるのに対して、人の手で設定する学習の更新回数や更新率などの学習に関するパラメータであり、適切に設定を行わなければ、過学習や未学習の状態になるほか、学習が進まないため低い精度のネットワークになってしまう。設定する値は分類する問題によって異なる。本研究ではCNN内のハイパーパラメータは、表-1に示すように設定をした。

表-1. 設定したハイパーパラメータ

イテレーション率	0.0001
最大エポック数(回)	1000
ミニバッチサイズ(個)	300
モメンタム	0.9

本研究では学習に使用する画像は、空撮画像から現地調査に基づくアマモ場領域と他の植生の領域について 20×20 pixel で切り出したものを使用した。学習に使用した画像を教師データ、検証に

使用した未学習の画像を、**図-2**、**図-3**に示す。画像データ数はそれぞれ、約 20000 パターン用意し学習に約 17,000 枚、検証に約 3000 枚を使用した。

図-2. アマモ場教師データ画像

図-3. アマモ場以外の藻場の教師データ画像

3. 解析結果と考察

アマモ、その他の植生の画像データについて構築したネットワークを用いて判別したときの結果を表-2に示す。判別結果として、 TP はアマモをアマモと判別できた数、 TN はアマモ以外をアマモ以外と判別できた数、 FP はアマモをアマモ以外と判別した数、 FN はアマモ以外をアマモと判別した数を表している。

表-2. 混合行列の構成

		判別の結果	
		正	負
真の結果	正	$TP: 2729$	$FN: 301$
	負	$FP: 271$	$TN: 2699$

判別精度を A_c とすると、式 (1) に示すように、アマモと判別したもののうち、実際に真であったものの割合であり、判別精度： $A_c=90\%$ の精度が得られる。また、判別精度の推移について教師データの推移を Training、検証データでの推移を Validation として**図-4**に示す。

$$A_c = \frac{TP}{TP + FP} \quad (1)$$

図-4. 識別精度の推移

横軸はエポック、縦軸は精度を示している。教

師データ及び検証データは類似しており、各データの差が小さいため、過学習は起きていないと考えられる。次にアマモ場以外の植生の判別に関して考慮した評価指標として F_m を計算する。 F_m は式 (2) で算定でき、値が 1 に近づくほど判別の評価が高い。

$$F_m = \frac{2 \times \left(\frac{TP}{TP + FP} \right) \times \left(\frac{TP}{TP + FN} \right)}{\left(\frac{TP}{TP + FP} \right) + \left(\frac{TP}{TP + FN} \right)} \quad (2)$$

表-2 に示す混合行列をもとに計算した結果、 F 値： $F_m=0.91$ であった。このことから、アマモの分類手法として CNN の有用性について示すことができた。

4. おわりに

本研究では、アマモ場分類のための基礎実験として機械学習手法である CNN を利用した分類を試みた。本研究では対象海域や撮影高度・学習データなどはあまり考慮せずに、CNN のネットワーク構築の最もキーポイントとなる適切なハイパーパラメータの設定をすることで、アマモ場分類手法としての CNN の有効性について検証した。その結果、CNN を用いたアマモ場の分類は約 90% の精度で分類をすることが可能である。また、本研究での CNN のハイパーパラメータとして考慮していない学習に用いるデータ画像のサイズや撮影高度の変化を考慮した画像データを用いての学習を行うことでより高精度でのアマモ場分類が可能になると考えられる。今後、これらの点を踏まえてハイパーパラメータの設定を行えば、本研究で構築した CNN の精度向上に及び汎用性の向上につながると考えられる。

参考文献

- 1)大前和広, 作野裕司他: 気球搭載用簡易分光カメラを利用したアマモ分布図作成のための基礎実験, 水工学論文集, 第 52 巻 pp1357-1362, 2008.
- 2)澤井泰基他: ローカルリモートセンシングによるアマモ場植生の分布調査手法に関する研究-Snake 法によるアマモ場の画像抽出に関する検討-, 中部支部研究講演概要集, pp193-194, 2017.3.