

機械学習によるため池水面画像内のヒシ葉検出の試み Machine Learning for detecting water chestnut leaves on pond surface using image processing

○溝口 優作 近藤 雅秋
Yusaku Mizoguchi Kondo Masaaki

1. はじめに

近年、人口知能（以降 AI とする）の発展により、医療、農業、製造、セキュリティなど様々な分野で AI 技術が活用されるようになってきた。中でも画像解析分野では、機械学習を用いた研究が盛んに行われており、その中核技術として深層学習が注目されている。深層学習とは、AI が大量のデータから自動的に特徴を学習することで、高度な認識や判断を可能にする手法である。画像解析への応用例の一つにセマンティックセグメンテーションがあり、これは画像中の各ピクセルをカテゴリ別に分類するもので、自動運転への活用や医用画像診断などに利用されている。セマンティックセグメンテーションには多くのモデルが存在し、代表的なものとして CNN（畳み込みニューラルネットワーク）、U-Net、DeepLab などがある。中でも DeepLab シリーズは、Google AI チームによって開発された高性能なセグメンテーションモデルであり、膨張畳み込みや空間ピラミッドプーリングといった独自の技術により、従来のモデルよりも高精度な解析が可能となっている。DeepLab は画像の細部から全体構造までを高精度に捉えることができるため、自動運転や地図作成、医療診断支援など、さまざまな分野への応用が期待されている。本研究では、DeepLab を用いた深層学習によって、ため池水面に繁茂するヒシ葉の被覆割合を検出し、その有効性を検証した。

2. 方法

2.1 DeepLab について

DeepLab は Google が開発した画像セグメンテーション用の深層学習モデルであり、特に DeepLabv3+ はその最新版として、膨張畳み込みや空間ピラミッドプーリングといった手法を取り入れている。膨張畳み込みは、解像度を保ちながら広い受容野を持つことができ、小さな物体から大きな構造までを同時に捉えることが可能である。空間ピラミッドプーリングは、異なるスケールで画像を処理し、多様なサイズの物体を効果的に認識できるようにするものである。



図 1 学習に使用した画像の例

Figure1 Example of images used for learning

る。本研究では、DeepLabv3+を用いて画像のセマンティックセグメンテーションを行った。実装には Python を使用し、開発および学習環境として Google Colab を利用した。学習に使用した画像は、大沢池においてドローン（高度 10m）で撮影したものであり、葉と水面の判別が容易な画像を選定した（図 1 参照）。訓練データ枚数と検証データの枚数と割合は表 1 にまとめた。エポック数は全て 100 回、バッチサイズは 16、学習率は 0.005 と設定した。画像サイズはすべて 256×144 ピクセルに統一している。ラベル付け（アノテーション）には、一般

三重大学 MieUniversity 機械学習、ヒシ、画像解析

的に用いられる Labelme などのツールは使用せず、大津の二値化処理を用いた。用いた理由は、「葉」と「水面」の2クラスに分類することに、大津の二値化処理を用いることで簡便かつ効率的なラベリングが可能であると考えたためである。

2.2 評価方法

学習した DeepLabv3+モデルを用いて、6枚の異なる特徴を持つ画像に対してセグメンテーションを実施した。6枚の画像はそれぞれ表2のような特徴を持っている。それぞれの画像において、モデルの出力結果と、目視により手作業で作成した教師画像との IoU (Intersection over Union) を計算し、精度を評価した。加えて、同じ画像に対して大津の二値化処理による IoU も算出し、比較を行った。

3. 結果および考察

表1 訓練データと検証データについて

Table 1: Training data and validation data

	訓練データ(枚)	検証データ(枚)	訓練データ:検証データ
グループ1	244	27	9:1
グループ2	213	54	8:2
グループ3	187	80	7:3

表2 6枚の画像の特徴

Table 2: Characteristics of the 6 images.

- ・ヒシが少ない
- ・ヒシが多い
- ・水面が緑に濁っている
- ・雲が水面に映っている
- ・葉が太陽光を反射
- ・太陽が水面に映っている

表3 DeepLabv3+による評価結果

Table 3: Evaluation results using DeepLabv3+.

	ヒシ少ない	ヒシ多い	水面緑	雲	太陽反射	太陽映り込み
グループ1	69.25	79.76	1.65	0.07	84.16	24.93
グループ2	70.32	80.08	45.22	33.63	44.3	32.02
グループ3	79.47	76.42	31.02	13.01	81.95	35.13
大津の二値化処理	91.65	89.91	71.03	67.02	75.01	25.78

表3に DeepLabv3+を用いた各学習条件下での IoU を示す。ヒシの量が少ない画像、ヒシが多く覆う画像、太陽光の反射がある画像では、いずれも IoU の値が高く、比較的良好な結果が得られた。一方で、残りの3枚では IoU が 50%を下回り、精度が劣る結果となった。この原因として、学習に用いた画像の構成が影響していると考えられる。今回の学習データには、葉と水面のみが明確に写った画像を使用しており、太陽光や雲などの要素を含む画像に対する認識が困難であったことが推測される。さらに、DeepLabv3+と大津の二値化処理による IoU を比較する。全体的には大津の方がやや精度が高い傾向にあるが、太陽光の反射や映り込みがある画像では、DeepLabv3+の方が高い精度を示す場合も確認された。これは、深層学習が持つ多様な特徴抽出能力により、大津の二値化処理では検出が困難な画像にも対応できたためと考えられる。

4. おわりに

本研究では、DeepLabv3+を用いてため池水面に繁茂するヒシ葉の被覆割合を検出する手法を検討した。その結果、ラベル付けに大津の二値化処理を活用することで作業効率を向上させることが可能であり、また、深層学習を用いることで、太陽光や雲の映り込みなど、複雑な条件下においても一定の検出性能を発揮することが確認できた。今後は、より多様な画像を学習に取り入れることで、さらなる精度の向上を目指す。