

深層学習を用いた UAV 画像による海岸漂着ゴミ抽出の試み

日大生産工(院)○山崎 敬亮 日大生産工 武村 武

1. はじめに

近年、海洋に漂流する多くのゴミが問題視されている。加えて、沿岸部における漂着ゴミについても、環境問題としてあげられている。漂着ゴミの中でも特に大きな課題の一つでは、プラスチックゴミである。高田ら¹⁾は、劣化して小さくなったプラスチックであるマイクロプラスチックを、動物プランクトンが体内に取り込み、食物連鎖を通して生態系全体に影響が出ていると述べている。また、三小田ら²⁾は有害成分による海洋汚染の恐れがあるとも述べている。このように、プラスチックゴミの問題は世界規模でも注目されている。さらに、2019年に大阪で開催されたG20サミットでは、2050年までに海洋プラスチックごみによる追加的な汚染をゼロにまで削減することを目指す「大阪ブルー・オーシャン・ビジョン」が共有された³⁾。このビジョンでは、プラスチック削減、リサイクル、教育、環境保護、国際協力などを通じて海洋プラスチックの問題に対処し、都市の持続可能な発展を追求するなど、世界で関心が高まっている。

千葉県船橋市に位置する三番瀬は、東京湾の最奥部に位置しており約1800haの干潟・浅海域である。現在、三番瀬には多くの漂着ゴミが確認され⁴⁾、そのゴミの大半は貝殻と植物の枯死体である。村上⁵⁾は、三番瀬における漂着ゴミに含まれるMPゴミの堆積量を把握する事を目的に、調査・分析し検討した結果、マイクロプラスチック量の推定をする際には、植物ゴミに注目すると良いと述べている。しかし、沿岸部には目視では把握しきれないほどの植物ゴミが漂着しており、沿岸部全域の植物ゴミを把握するためには、把握手法の効率化を図る必

要がある。

そこで、本研究では沿岸部の漂着ゴミの分布状況把握を目指し、その前段階として三番瀬においてUAVにより取得された画像から、深層学習による植物ゴミの抽出の可能性について検討を行った。

2. 画像解析概要

本研究では、深層学習を用いて物体検出を行うために、物体検知モデルの1つであるYou Only Look Once(YOLO6)というアルゴリズムを用いた。YOLOは、リアルタイムタイム検出アルゴリズムと呼ばれており、処理速度が速い点が特徴であり、物体の位置と種別を同時に予測することが可能なアルゴリズムである。

(1) 使用データ概要

使用した画像データは、2023年5月26日に千葉県船橋市に位置するふなばし三番瀬海浜公園にて撮影した画像を用いた。撮影は、UAV(DJI社Mavic 2 Enterprise DUAL)を用いて撮影高度が14mとなるように設定し、海岸を真上から撮影を行った。画像抽出を行うために、解析に用いた各々の画像に対して植物ゴミの領域を抽出してラベル付けを行った。図1にラベル付け(バウンディングボックス)のイメージ図を示す。各々の画像におけるバウンディングボックス数は一定では無く、8~68個の範囲であった。

画像データは総データとして100枚を用意し、それを学習用データ(train)、検証用データ(validation)、テストデータ(test)に分類した。その割合は、一般に良く用いられるtrain:validation:test=7:2:1とした⁷⁾。




図1 ラベル付けイメージ

(2)解析方法

YOLO の一般的な解析フローは、まず学習用データで、モデルをトレーニングし、調整を行う。次に、検証用データで性能評価を行い、その後テスト用データを用いて推論し、対象物体の抽出を行う。

表 1 に解析を行う際に設定した基準パラメータ一覧を示す。表 1 のパラメータを基準値として、深層学習の動作を設定し、各パラメータを変化させ解析し結果の比較を行った。なお、学習用データは、画像 100 枚中のバウンディングボックス数を 481~5000 個まで 6 パターンを設定した。同様に検証用データでは、749~1600 個まで 6 パターンを設定した。さらにエポック数の影響を検討するために、10~250 回まで 6 パターンを設定し、検討を行った。

表 2 に、データの二値分類において正事例と負事例の予測でよく用いられる混同行列を示す。本研究では、テストデータに正答を設定し、それとの適合率を評価指標とした。適合率の定義式は以下の通りである。

$$\text{適合率} = \frac{TP}{TP+FP} \quad (1)$$

ここに TP は正解データと予想したデータが共に真であるもの、FP は正解データが偽で予想したデータが真のものである。

表 1 解析に用いた基準のパラメータ一覧

項目	基準の設定
ウェイトファイル	Yolov5m.pt
バッチサイズ	16
エポック数	200回
入力サイズ	480×640
総バウンディングボックス数(学習用)	2360個
総バウンディングボックス数(検証用)	749個

表 2 混同行列

	実際は正 (Positive)	実際は負 (Negative)
予測が正 (Positive)	True Positive (TP)	False Positive (FP)
予測が負 (Negative)	False Negative (FN)	True Negative (TN)


3. 結果と比較

はじめに、学習用データ内や検証用データ内のバウンディングボックス数の違いおよびエポック数の違いが、画像抽出時の適合率に与える影響を検討した。

図 2 に学習用データに用いたバウンディングボックス数の違いによる抽出結果への影響の比較画像の例(481 個と 5000 個)、図 3 に検証用データに用いたバウンディングボックス数の違いによる抽出結果への影響の比較画像の例(749 個と 1200 個)、図 4 にエポック数の違いによる抽出結果への影響の比較画像の例(10 回と 200 回)を示す。


図 2(b)の結果は図 2(a)の結果に対して 3.36 倍のバウンディングボックス数であり、図 3(b)の結果は図 3(a)の結果に対して 1.08 倍のバウンディングボックス数であった。これらの結果より、学習用データでは、個数を増やすと抽出結果に大きく影響を与えるが、検証用データではあまり影響がないことがわかった。さらに、図 4(b)は図 4(a)の結果の 25.5 倍のバウンディングボックス数が確認出来、同じデータでもエポック数を多くすることにより抽出結果が大きく変化する事がわかった。

ここで学習用データ内、および検証用データ内のバウンディングボックスの変化に伴う適合率を検討した。その結果を図 5 および 6 に示す。



(a) 481個 (b) 5000個

図2 学習用データに用いたバウンディングボックス数の違いによる抽出結果の違い



(a) 749個 (b) 1200個

図3 検証用データに用いたバウンディングボックス数の違いによる抽出結果の違い



(a) 10回 (b) 200回

図4 エポック数の違いによる抽出結果の違い

図5の結果より、481個を学習させた場合の適合率は、19.2%であったが、5000個を学習




図5 学習用データ内のバウンディングボックス数と適合率のグラフ




図6 検証用データ内のバウンディングボックス数と適合率のグラフ




図7 エポック数と適合率のグラフ

させた場合の適合率は61.0%となった。両者の結果を比較すると、図2(b)で示したようにバウ

ンディングボックス数を増やすことで、より多く植物ゴミを抽出可能であることがわかった。

次に、図6の結果について検討する。なお、学習をさせるに際し、学習用データのバウンディングボックス数は、適合率が最も良好であった5000個に設定し比較を行った。図6の結果より、749個を学習させた場合の適合率は61.0%となり、1600個を学習させた場合の適合率は68.4%となった。また、1200個より個数を増加させても、適合率にあまり変化は現れなかったため、効率よく植物ゴミを把握するためには、図3(b)のように検証データ内のバウンディングボックス数を1200個にするとよいと考えられる。

図7に、エポック数の違いが適合率に与える影響の結果を示す。なお学習させるあたり、学習用及び検証用データ内のバウンディングボックス数は、これまでの検討において最も良好な適合率であった5000個と1200個に設定し比較を行った。図7より、エポック数が10回の適合率は2.6%となり、250回の適合率は64%であった。またエポック数が200回を超えると適合率に大きな影響を与えない結果となった。よって今回の条件下において効率よく植物ゴミを把握するためには、エポック数200回が適正であると考えられる。

4. まとめ

本研究では、沿岸部のマイクロプラスチックの堆積量を効率的に把握するための前段階として、YOLOを用いた画像解析を行い、漂着ゴミ(植物ゴミ)の抽出を試みた。

その結果、今回用いた画像において漂着ゴミの抽出を行う為の条件としては、学習データ内のバウンディングボックス数は5000個、検証

データ内のバウンディングボックス数は1200個、学習回数は200回であり、この条件で約7割の漂着ゴミを抽出することができた。

よって、植物ゴミは幾何学的に不規則であるが、学習量や学習回数の適切な設定を行うことで一定程度の抽出が可能であることが示唆された。今後は、撮影日の違いや撮影場所の違いによる等による影響を検討する予定である。

参考文献

- 1) 三小田憲史, 水環境汚染の評価に向けた海洋マイクロプラスチックの分析, 分析化学, 68巻11号, p.853-857, 2019
- 2) 高田秀重, 海洋プラスチック汚染とその対策, 24巻, 10号, (2019)p10_44-10_48.
- 3) 外務省, G20 大阪サミットにおける海洋プラスチックごみ対策に関する成果, <https://www.mofa.go.jp/mofaj/files/000529033.pdf>, (参照 2023-10-5)
- 4) 栗山雄司, 小西和美, 兼広春之 他, 東京湾ならびに相模湾におけるレジンペレットによる海域汚染の実態とその起源, 68巻, 2号, (2002)p.164-171.
- 5) 村上裕子, UAV 画像を用いたマイクロプラスチック堆積状況の検討, 2022.
- 6) Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, "You Only Look Once: Unified, Real-time, Object, Detection", (2016) pp.779-788.
- 7) 嶋田雅也, 倉橋貴彦, 村上祐貴, 池田富士雄, 井原郁夫, 打撃応答波形を用いた畳み込みニューラルネットワークによるコンクリート内の無次元密度分布の同定, 日本機械学会論文集, Vol.87, No.904(2021) pp.21-00266.