

河川マクロプラスチック面積・種類判別への深層学習の適用

東京理科大学大学院 ○太田 洸

愛媛大学大学院 片岡智哉、東京理科大学 吉田拓司、二瓶泰雄*

* nihei@rs.tus.ac.jp

マイクロプラ

Application of Deep Learning to Area and Types of Floating Macroplastics in Rivers, by Hiro OTA (Tokyo Univ. of Science), Tomoya KATAOKA(Ehime Univ.), Takushi YOSHIDA, Yasuo NIHEI(Tokyo Univ. of Science)

1. はじめに

2019年G20の「大阪ブルー・オーシャン・ビジョン」では、2050年に海洋へのプラスチックごみ排出を実質0とすると宣言された。海洋プラごみの8割が陸域起源のため「どの河川から どのくらいプラごみが流出するか」を把握することは極めて重要である。5mm未満のプラスチック片（マイクロプラスチック）については観測手法がある程度確立され、各地でモニタリングされている。一方、5mm以上のプラスチック（マクロプラスチックと称す）に関しては観測手法が確立されておらず、実測データが非常に少ない。このため著者らは、河川水表面の動画連続撮影と色情報に基づく画像解析法（River Image Analysis for Debris flux, RIAD）に基づく川ごみ輸送量モニタリング手法を開発した¹⁾。しかしながら、RIADには人工系・自然系ごみを認知する閾値設定や水表面上の太陽光の反射や波紋による誤認識等の課題があり、かつ、プラ製品の種類判別は困難である。本研究ではRIADに代わる画像解析法として、近年進展が著しい深層学習に基づく河川マクロプラスチックの面積算出・種類判別手法を開発することを目的とする。そのため、実河川におけるプラごみ浮遊状況を撮影し、学習・予測データとして用いる。プラごみの面積推定手法には画像の深層学習に一般的なCNN（Convolutional Neural Network）、種類判別手法には物体検知に一般的なYOLO（You Only Look Once）を各々用いる。本稿は太田ら²⁾の一部である。

2. 平常時河川のデータ収集方法と結果

(1) 観測概要

深層学習用の学習・予測データを収集するために、実河川の水表面を浮遊するプラスチックを含む人工系及び自然系ごみを撮影した。観測場所は千葉県柏市大堀川・勝橋であり、観測日は2020/9/17の平常時であった。現地では、橋上の欄干に3台のDVカメラを鉛直下向きに設置し、撮影範囲（約2.1m×1.1m）の上流側から予め用意したごみを流し、下流側で回収した。画像の解像度はカメラにより異なるが、後述の解析には3840×2160ピクセル、倍率4倍で撮影された画像を用いた。用いたごみは人工系125個、自然系50個であり（表-1）、ごみを一つずつ計6回流し、深層学習に必要な画像を集めた。

(2) 人工系ごみ面積の算出精度

CNNによるごみ面積の算出精度を検討するため、

表-1 学習・検証データに用いた平均ごみ面積と画像枚数（ピンク：プラスチック、水色：非プラスチック、緑：自然系ごみ、無色：水面）

ごみ種類	ごみ面積 [cm ²]	画像枚数	ごみ種類	ごみ面積 [cm ²]	画像枚数
ペットボトル	170	145	缶	95	35
プラ容器	192	80	瓶	53	14
プラ袋	355	49	紙パック	162	3
ストロー	15	49	自然系	10819	28
食品トレイ	242	47	葉	996	88
たばこ吸い殻	5	24	水面のみ		11
ライター	11	12	13種類	計585枚	



元画像



CNN



RIAD(75)



RIAD(100)

(a)プラ袋 (b)ペットボトル

図-1 CNN・RIADによるプラごみ面積の検出結果の例（白色：プラごみ、黒色：その他）

プラ袋とペットボトルを例に、元画像とCNNとRIADの面積算出結果を図-1に示す。解析結果ではプラごみとそれ以外をそれぞれ白色、黒色で示す。なお、RIADではプラごみ判別の閾値を75と100とし

た結果を示す。まず、CNN ではプラ袋とペットボトルを概ね再現できたが、ペットボトルの透明部分を一部見逃した。また、RIAD では、閾値 75 ではプラ袋とペットボトル以外に白色が点在し、ごみ面積を過大評価した。一方、閾値 100 ではプラ袋の一部が見逃され、ペットボトルを全く再現できていない。

(3) ごみ種類判別精度

YOLO によるごみ種類毎の判別精度を表-2 に示す。ここでの正解率は、対象のごみ種類を的中できたかどうかを示す。これより、自然系の束・枝は精度が低いが、人工系は全般的に精度が高いことが分かる。このように現在設定したごみ種類程度であれば、YOLO により概ね種類判別できている。

3. 出水時河川のマクロプラごみ判別の適用

(1) 検討手法の概要

前述した河川マクロプラスチックごみの種類判別手法である深層学習モデル YOLO を、実際の出水時河川モニタリングに適用できるかを検証する。対象サイトは、著者らが別途観測を行った三重県四日市市市を流れる天白川流域内の排水路（住所：三重県四日市市市日永東 2 丁目）である。ここでは、2019 年 8 月～2020 年 9 月において、出水時を含み連続的に撮影された動画から、ごみを含む 137 枚の画像を学習・検証画像とした。大堀川で作成した学習モデルと比べるため、3 種類のデータセット（①大堀川の画像 585 枚、②排水路の画像 87 枚、③①と②を合わせた 672 枚）を用意した。ゴミの判別種類は Case1:人工系 or 自然系、Case2:プラ or 非プラ or 自然系、Case3:種類別とし、排水路の画像 50 枚（計 62 個の人工系ごみ）を対象に精度検証を行った。

(2) 結果

3 つの Case のマクロプラごみの判別種類において、学習データ①～③を用いた時の正解率を図-2 に示す。この正解率は、検証用ごみ個数に対してごみ種類を判別できた個数の割合である。これを見ると、正解率は、全ケース共に、学習データ①<学習データ②<学習データ③の関係となっている。これより、大堀川の画像よりも現地河川（排水路）の画像が重要であること、さらに、両者をミックスして画像数を増やすことがゴミ判別精度向上に大きく寄与していることが分かる。また、ごみ判別種類数が増えるほど全体の正解率も下がるが（すなわち Case1>Case2>Case3）、学習データ③を用いた Case3 の正解率は 47 % であり、平常時大堀川の結果をやや下回る程度と良好な結果であった。

以上より、YOLO は、学習データを増やし、かつ、対象サイトの画像を組み込むことが、マクロプラごみ判別精度向上につながる。このため、今後はマクロプラごみの画像を収集・蓄積していくことが必要不

表-2 YOLO によるごみ種類毎の判別精度

ごみ種類	検証枚数	正解率	ごみ種類	検証枚数	正解率
ペットボトル	14	71%	缶	4	75%
プラ容器	6	83%	瓶	4	25%
プラ袋	2	50%	紙パック	1	0%
ストロー	2	100%	自然系	10	20%
食品トレイ	4	75%	葉	8	88%
たばこ吸い殻	2	50%	水面のみ	1	100%
ライター	1	0%			

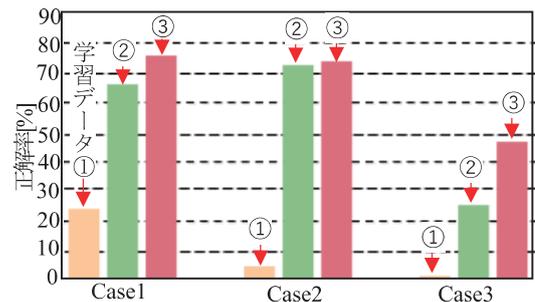


図-2 Case1～3における学習データ①、②、③を用いた時の人工系ごみの判別精度（正解率）の比較

可欠である。特に、様々な天候条件（特に出水時）や昼夜条件における動画撮影を行うことが求められる。この現地河川において水表面を撮影する時には、プラ袋やペットボトルなどの主要なマクロプラスチックごみを特定できる程度の解像度を設置する必要がある。また、YOLO モデルの精度向上に対して、どんなごみ画像をどのくらいの枚数（個数）、学習させるかは不明確であり、今後の検討課題である。

4. 結論

本研究により得られた主な知見は、以下の通りである

- 1) 平常時河川に関して、CNN は、水面に浮かぶ人工系ごみの一部を見逃すが、RIAD よりも高精度のごみ面積算出方法であることが示された。同様に、YOLO によるごみ種類判別精度は、自然系の束・枝では低いが、人工系ごみは全般的に高かった。
- 2) YOLO を実際の出水時河川に適用できるか検証した結果、学習データを増やし、かつ対象サイトの画像を取り込むことで判別精度の向上につながった。

参考文献

- 1) Kataoka, T. and Nihei, Y.: Quantification of floating riverine macro-debris transport using an image processing approach. *Scientific Reports*, Vol.10, pp.1–11, 2020.
- 2) 太田洗・片岡智哉・吉田拓司・二瓶泰雄：深層学習に基づく河川マクロプラスチック面積算出・種類判別手法の開発，土木学会論文集B1（水工学），2021（投稿中）。