

## 河川マクロプラスチック面積算出・種類判別に向けた深層学習の適用

東京理科大学大学院 学生会員 ○太田 洸  
 愛媛大学 正会員 片岡 智哉  
 東京理科大学 正会員 二瓶 泰雄

### 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。海洋プラスチックの8割が陸域起源のため「どの河川から どのくらいプラスチックが流出するか」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。このため著書らは、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（RIAD, River Image Analysis for Debris flux）に基づくマクロプラスチック輸送量モニタリング手法を開発した<sup>1)</sup>。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、プラスチック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スチック浮遊状況を撮影し、学習・予測データとして用いる。プラスチック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。

### 2. 研究手法

**(1) 実河川のプラスチックデータ収集：**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、観測日は2020年9月17日であり、流況は平常時であった。現地では、**図1**に示すように、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（詳細は**表1**）、ごみを一つずつ計6回流した。

**(2) CNNによる面積算出方法：**水表面を浮遊するゴミの面積算出にはCNNによる「セマンティックセグメンテーション」を用いる。ここでは、各画素にて人工系ごみを検出し、面積を求める。解析前の準備に、実河川の撮影画像とその答え画像（ごみ部分を1、その他を0）を用意した。次に学習画像を**図2**に示すように、Convolution層にてカーネル（空間フィルタ）を用いた画像特徴量を抽出し、Batch Normalizationにて学習効率化のため入力値を正規化し（平均0, 分散1）、活性化関数ELU（0未満は-1~0, 0以上は入力値）を適用する。この3層を36回繰り返した結果に、二値化に使われるSigmoid関数（範囲; 0~1）を適用し、BinaryCrossEntropy層で答え画像との差が小さくなる重みやバイアスを求める。このフローを50エポック繰り返し、人工系ごみとそれ以外に二値化された画像を出力する大堀川の撮影動画より切り出した静止画424枚（人工系349, 自然系75枚）を学習、161枚（人工系109枚, 自然系52枚）を予測用にそれぞれ用いた。画像は高解像度版（3840×2160ピクセル）及び、その解像度を落とした低解像度版（960×540ピクセル）とした。さらに、学習・予測に適したサイズとするために各画像を256×256ピクセルで複数枚切り出した。なお、比較用にRIADによるごみ面積算出も行った。

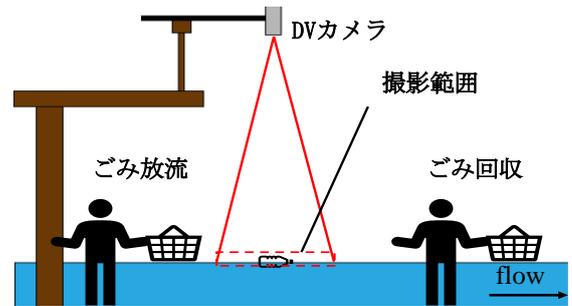


図1 深層学習用の河川浮遊ごみ撮影状況

表1 学習・予測データに用いたごみ種類と画像枚数（ピンク：プラ，水色：非プラ，緑：自然系）

ごみ種類	枚数	ごみ種類	枚数
ペットボトル	145	缶	35
プラスチック容器	80	瓶	14
プラスチック袋	49	牛乳パック	3
ストロー	49	自然系(葉、枝)	28
食品トレイ	47	葉	88
たばこ吸殻	24	水面のみ	11
ライター	12	13種類 計	585枚

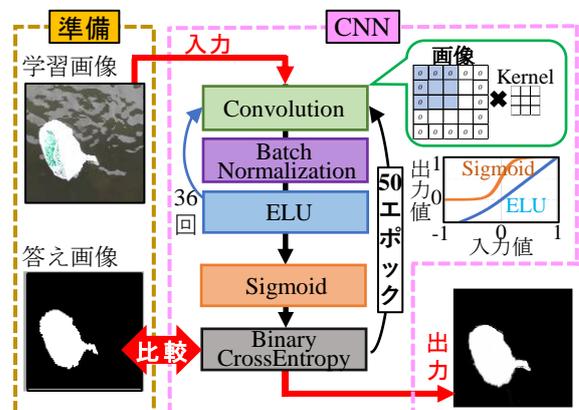


図2 CNNによるごみ面積の解析フロー

キーワード：マイクロプラスチック，マクロプラスチック，深層学習，CNN，YOLO

連絡先：〒278-8510 千葉県野田市山崎 2641 東京理科大学 5号館 3階 水理研究室 TEL：04-7124-1501（内線 4069）

**(3) 種類別プラごみ検出:** YOLO では、検出対象を取り囲む矩形枠 (Bounding box) の中心座標、幅、高さ、物体種類を CNN で検出し、画像をいくつかのグリッドに分割することでリアルタイムの高速検出が可能となる。モデルには最新版の YOLOv5 を用い、Google Colab 上で実装した。学習・予測データには、現地撮影された 585 枚を用意し、ごみ種類と準備枚数は表 1 に示すとおりである。画像サイズは 960×540 ピクセルである。答え画像には vott を用いて画像内の物体を種類ごとにタグ付けした。

**3. 結果と考察**

**(1) ごみ面積算出精度:** 深層学習によるごみ面積の算出精度を検討するため、レジ袋を例に元画像と CNN と RIAD の面積算出結果を図 3 に示す。CNN と RIAD の結果として、白色をごみ、黒色をその他として示す。RIAD にてごみ判別の閾値を 75 と 100 のケースを図示する。また CNN では低解像版の画像の解析結果である。これより、CNN ではレジ袋部分を正確に再現できているが、水面部分も一部ごみとして誤認識している (画像右下)。一方 RIAD では、閾値 75 ではレジ袋部分以外に白色が点在しごみ面積を過大評価しているが、閾値 100 ではレジ袋以外の白色はないもののレジ袋部分でも黒色があり正確に再現できていない。このように RIAD では閾値設定に鋭敏に解析結果が変化している。

面積算出精度を比較するため、深層学習の精度評価用の TP (ごみをごみと推定できた画素数)、FP (ごみと予測したが間違えた画素数)、FN (ごみでないが予測したが間違えた画素数) を算出し、次の 3 指標 (IoU, 見逃し率, 誤認識率) を求める。

$$IoU = TP / (TP + FP + FN) \quad (1a)$$

$$見逃し率 = FN / (TP + FN) \quad (1b)$$

$$誤認識率 = FP / (TP + FN) \quad (1c)$$

得られた結果を図 4 に示す。これより、オーバーラップ率と言われる IoU の中央値は CNN : 0.41, RIAD (閾値 100) : 0.23, RIAD (同 75) : 0.15 の順となり、CNN の解析結果の方が RIAD よりも正確に対象ごみと一致している。この CNN の IoU より、CNN は約半分の予測誤差が生じているが、これは誤認識率の中央値が 1.7 であることと関係し、図 3 に示すように、水面の波紋の一部を誤認識しているためである。ただし、見逃し率は CNN ではほぼ 0 であり、人工系ごみを着実に捕捉できている。以上より、CNN では一部の誤認識は残るが、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。

**(2) 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、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。詳細に見ると、一部の人工系ごみで正解率が低下した要因を検討するために、正解率の学習枚数やごみ面積の依存性を図 5 に示す。これより、使用枚数と共に正解率は向上しており、50 枚以上あれば正解率は 50% 以上になる。また、ごみ面積については小さすぎたり (<1000cm<sup>2</sup>)、大きすぎたり (>10000 cm<sup>2</sup>) すると正解率は低下した。前者は画像解像度の問題、後者は画像サイズ (=23100cm<sup>2</sup>) と比べて大きく Bounding box の設定ができなかったためと推察される。今後、学習枚数を増やすと共に、適切な解像度や画角サイズを設定し YOLO の種類判別精度向上を行う必要がある。

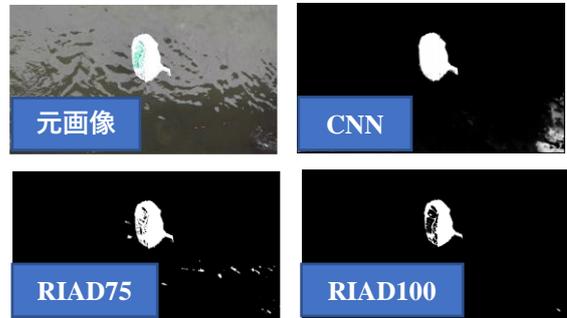


図 3 CNN と RIAD (閾値 75, 100) によるプラごみ面積の検出例 (ごみ種類: レジ袋の場合)

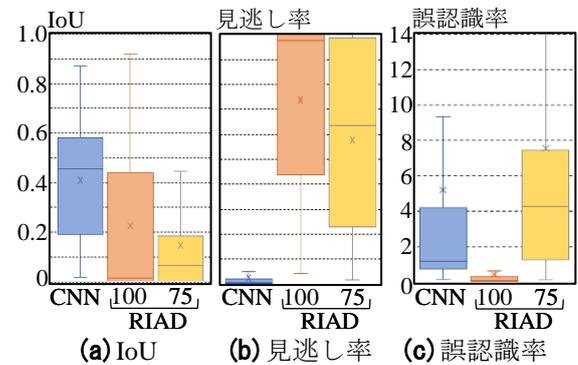


図 4 CNN と RIAD におけるごみ面積算出用の各種指標の比較

表 2 YOLO によるごみ種類毎の判別精度

ごみ種類	正解率	ごみ種類	正解率
ペットボトル	71%	缶	75%
プラ容器	83%	瓶	25%
プラ袋	50%	牛乳パック	0%
ストロー	100%	自然系(束、枝)	20%
食品トレイ	75%	葉	88%
たばこ吸殻	50%	水面のみ	100%
ライター	0%	13種類	

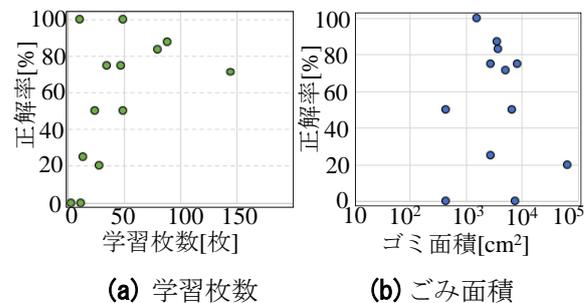


図 5 YOLO による正解率の低下要因の検討

参考文献: 1) Kataoka, T & Nihei, Y., *Scientific Reports*, 10, 2198, 2020.