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

太田 洸1・片岡 智哉2・吉田 拓司3・二瓶 泰雄4

 ¹学生会員 東京理科大学大学院理工学研究科土木工学専攻 (〒278-8510 千葉県野田市山崎 2641)
E-mail: 7621507@ed.tus.ac.jp(Corresponding Author)

²正会員 愛媛大学大学院准教授 理工学研究科生産環境工学専攻環境建設工学コース (〒790-8577 愛媛県松山市文京町 3) E-mail: tkata@cee.ehime-u.ac.jp

³正会員 八千代エンジニヤリング(株) 事業統括本部 (〒111-8648 東京都台東区浅草橋 5-20-8) E-mail: tk-yoshida@yachiyo-eng.co.jp

> ⁴正会員 東京理科大学教授 理工学部土木工学科 (〒278-8510 千葉県野田市山崎 2641) E-mail: nihei@rs.tus.ac.jp

海洋プラスチックごみの多くは陸域起源であり、河川経由で海洋に流入する 5 mm 以上のマクロプラス チックごみを計測することは重要である.本研究では、深層学習に基づいて、河川を浮遊するマクロプラ スチックの面積や種類判別のための新たな画像解析手法を開発することを目的とする.学習データ作成の ために、平常時河川において水表面に浮かぶ様々な人工系・自然系ごみを撮影し(計 585 枚)、深層学習 モデルには CNN と YOLOを用いた.その結果、CNN と YOLO はそれぞれ、人工系ごみ面積やプラスチッ クごみ種類判別を高精度で捉えることができた.また、YOLO を出水時河川にも適用し、現地で撮影され たごみ画像を学習データに加えることで、プラスチックごみの種類判別精度が大幅に向上した.

Key Words: macroplastics, microplastics, image analysis, deep learnning, YOLO

1. はじめに

近年,海洋におけるプラスチックごみ汚染が世界的な 環境問題となっており,生態系への影響も顕在化してい る^{1)~4)}.国際的な取り組みが進められる中^{5,6},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にする と宣言された⁷⁾.海洋プラごみの8割が陸域起源のため ⁸,「どの河川からどのくらいプラスチックごみが流出 するか」を把握することは極めて重要である.

5 mm 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ており、わが国 の河川でも全国各地でモニタリングされている^{9,10}.一 方、5 mm 以上のプラスチック(マクロプラスチック) 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.一方、Kataoka and Nihei¹¹⁾は、河川水表面 と浮遊ごみの色差値を用いて、川ごみ輸送量モニタリン グするための画像解析手法(RIAD, River Image Analays for Debris flux)を開発した. この RIAD の解析対象は, プ ラスチックごみなどの人工系ごみと植生などの自然系ご みから成る川ごみ全体であり, 色差値の閾値を設定して 水表面と川ごみ全体の判別(二値化)を行った. さらに, 現在では2つの閾値を設定し,水表面と人工系ごみ, 自 然系ごみの判別(三値化)も実施している^{10,13}.この RIAD は一定の有用性が分かっているが,人工系・自然 系ごみを認知する閾値を水域毎に設定する必要があるこ とや, プラスチック製品の種類判別は現状では困難であ るため,新たな解析技術が必要となる.

この種の画像解析には、近年進展が著しい深層学習 (Deep Leaming) が有用である.深層学習とは人間の脳 神経回路をモデルとしたニューラルネットワークを用い て、大量のデータから特徴量を自動で学習し予測を行う 手法である^{14),15}.この深層学習を画像分野に応用する と、対象物体の特徴を自動で学習し物体の位置や種類を 特定できる^{16),17}.深層学習は河川環境モニタリングに も適用されているが(例えば、中谷ら¹⁸),河川のマ



クロプラチックごみへの適用例は皆無である.

本研究では RIAD に代わる画像解析法として,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,まず平 常時の実河川にてプラスチックごみの浮遊状況を撮影し, 深層学習に必要な学習・検証用データとして用いた.プ ラスチックごみの面積推定手法としては,画像の深層学 習に多用される CNN (Convolutional Neural Network)¹⁹を 用いたセマンティックセグメンテーション (Semantic Segmentation)²⁰を用いる.また,種類判別手法には,物体 検知モデルの1つである YOLO (You Only Look Once)²¹⁾ を用いる.さらに,実際の出水時における河川水表面を 撮影した画像を用いて,本研究で開発した深層学習モデ ルの適用性を検証する.

2. 平常時河川のごみデータ収集・解析方法

(1) プラスチックごみデータ収集

様々な種類・数の深層学習用の学習・予測データを収 集するため、平常時の実河川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 は千葉県柏市を流れる大堀川・勝橋である(図-1). 観 測日時は2020年9月17日10~16時であり、流況は平常 時であった. 現地では、図-2に示すように、橋上の欄干 に3台のDVカメラ(HC-WX990M, Panasonic製)を鉛直 下向きに設置し、撮影範囲の上流側から予め用意したご みを流し、下流側で回収しその様子を撮影した. 得られ 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:プラスチックごみ,水色:非プラスチッ クごみ,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 | 放 |

た動画を1秒毎に分割し静止画を作成した.画像の解像 度はカメラにより異なるが、後述の解析には範囲 2.1m × 1.1m, 3840 × 2160 ピクセル (px) (=0.055*0.051 cm/px),倍率4倍で撮影された画像を用いた.

用いたごみを表-1に示す.自然系ごみには枝や葉等の 50個とした.使用済みのごみを1つずつ計6回流し,そ の様子を撮影した.今回の最小のごみは,たばこの吸い 殻であった(=4.16 cm²).

(2) CNNによる人工系ごみの面積算出方法

水表面を浮遊するごみの面積算出には CNN によるセ マンティックセグメンテーションを用いる. セマンティ ックセグメンテーションは画素単位で物体を特定する手 法であり,これを用いることで,各画素にて人工系ごみ を検出し,面積を求めることができる.

CNN による人工系ごみ面積の解析手順を図-3 に示す. まず、解析前の準備として、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, 学習画像に対して, Convolution 層においてカーネル (空 間フィルタ)を用いて画像特徴量を抽出する.二次元配 列である画像の一部に対して、カーネルをかけ、畳み込 み演算を行い、フィルターを平行移動させ画像全体に畳 み込みを行っている. Convolution 層の次の Batch Normalization では、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(Exponential Linear Unit,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、2 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 2 値 化された画像を出力する.本稿では、シンプルな CNN



図-3 CNN (セマンティックセグメンテーション) による 人工系ごみ面積の解析フロー

を用いているが、今後はより一般的な U-net 等を試す予 定である.

データとしては、大堀川の撮影動画より切り出した静止画 424 枚(人工系 349 枚,自然系 75 枚)を学習用, 161 枚(人工系 109 枚,自然系 52 枚)を検証用に各々用いた(合計 585 枚,表-1).同表には、用いたごみ種類の画像枚数も記載されている.河川堆積ごみの実測²⁰を参考に、多く見られるごみの画像枚数を多くした.解析上の負荷を減らすために、画像の解像度を元の3840×2160 ピクセルから 960×540 ピクセルに落としたものを解析に使用した.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.

また, CNN による人工系ごみの面積算出精度の比較 用として, RIADによるごみ面積算出も行った. RIADに おける人工系ごみとその他を分ける閾値としては,今回 は75と100の2種類とした.紙面の都合上,解析方法の 詳細は既往論文^{110,12}を参照されたい.

(3) YOLO による種類別プラスチックごみ検出

YOLO は物体の位置や種類を判別する物体検出モデル である.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.このよう な手法により、YOLO は深層学習の中でも計算負荷が小 さい.モデルには最新版のYOLOv5を用い、Google Colab 上で実装した.ごみ判別の種類分けとして、Case1:人 工系と自然系ごみ、Case2:プラスチックと非プラスチ ック、自然系ごみ、Case3:表-1に示す12種類のごみ、 という3ケースのモデルを作成した.なお、3ケースと もに、水面のみも含み解析した.

学習・予測データには、CNN と同様に、平常時の現 地河川(大堀川)で撮影された 585 枚を用い、ごみ種類



元画像



CNN



RIAD (閾値:75)





と準備枚数は表-1に示す. 画像サイズは960×540ピクセルである. 答え画像には vott ソフトを用いて画像内の物体を種類ごとにタグ付けした.

3. 平常時河川データに関する結果と考察

(1) 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、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4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ている.次に、 RIADでは、閾値75ではプラ袋とペットボトルの部分以 外に白色が点在し、ごみ面積を過大評価している.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.

次に、面積算出精度を定量的に比較する.深層学習の 精度評価に用いられる 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 (ごみでないと予測したが間違えた画素数)を算出し、 次の2指標(IoU、見逃し率)を求める.



図-5 CNN と RIAD の面積算出精度の比較((a)loU, (b)見逃 し率)

IoU = TP/(TP + FP + FN) (1a)

見逃し率 = FN/(TP + FN) (1b)

CNN と RIAD の解析結果に関して得られた2指標(*loU*, 見逃し率)を図-5に示す.これより,オーバーラップ率 と言われる *loU* の平均値は CNN では 0.75 であるが, RIAD の閾値 75, 100 ではそれぞれ 0.22, 0.15 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.低いことが望まれる見逃し率の平均値に関 しては, CNN < RIAD (閾値 75) < RIAD (同 100)の大 小関係となっている.

これより、*IoU*, 見逃し率の指標で CNN の方が 2 つの 閾値の RIAD よりも良好な結果となっている. CNN にお ける *IoU*の平均値は 0.75, すなわち 25%の予測誤差が生 じている. この誤差は, 見逃し率の平均値(=0.22) と 対応しており, 図4に示すように, ペットボトル透明部 分の一部を見逃したことを反映している. 以上より, CNN では一部の見逃しは残るが, 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 によるごみ種類の判別例として, Case3 での判別結果を図-6 に示す. これより, YOLO の Case3 では, ごみが矩形領域で囲まれ, ごみ種類も正確に判別できて いることを確認される. なお, 種類判別できたケースの 分類確率(図-6中の数値)は0.45以上であった. ごみの 正解率(=正解枚数/検証枚数)は Case1, 2, 3 で各々 88.5, 83.6, 61.0 %となった. これより, ごみの分類数が 細かくなるほど正解率が減少している. このように, 自 然系・人工系ごみの判別(Case1)やそれにプラスチッ



図-6 YOLOの Case3 におけるごみ種類判別例(左:ペットボ トル,右:食品トレイ,平常時大堀川)

表-2 YOLO・Case3 におけ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-7 YOLO による正解率の低下要因の検討((a)学習枚数, (b)ごみ面積)

クの有無を分類する Case2 では概ね良好に分類できる. また, Case3 における正解率をごみ種類毎に見てみると (表-2),自然系の束・枝の正解率は低いが,人工系ご みは全般的に正解率が高い.また,検証枚数の少ないラ イターや紙パックは正解率 0%である.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.

Case3 において人工系ごみの一部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 依存性を検討した(図-7).同図(a)より,正解率は学 習枚数 50 枚程度までは向上するが,それ以上では 80% 程度になる.ただし,同じ程度の学習枚数でも正解率に ばらつきが見られる(例えば,図中△と○).その一つ の要因としてごみ面積が関係し(同図(b)),ごみ面積 が小さすぎ(<100 cm²)や大きすぎ(>10,000 cm²,図中 ○)で正解率は低下する.前者は画像解像度の問題,後 者は画像サイズと比べて大きく矩形枠の設定ができなか 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 精度精度向上を行う必要がある.

4. 出水時河川のマクロプラごみ判別への適用

(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を流れる天白 川流域内の排水路(住所:三重県四日市市日永東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面¹²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. ゴミの判別種類は前述の Casel~3 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) 結果と課題

まず,排水路を浮遊するマクロプラごみの判別例とし て, Case3 において学習データ③を用いたケースの結果 の一例を図-8に示す.このように,日中,排水路内に浮 かぶ2つのプラ袋を判別できている.また,検証画像に は夜間も含まれていたが,マクロプラごみを判別できた (図省略).そこで,3ケース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-9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 ごみ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.また、この ケースにおけるごみ種類毎の正解率を見ると(**表**-3)、 最も個数が多いプラ袋の検出精度が5割強であるが、個 数が少ないペットボトルは正解率も低い.なお、出水時 の画像には泡や波も見られたが、YOLOではごみと誤認 識しないことも確認された.

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.その際、河川に多く散乱するマク ロプラごみを中心に、画像を収集・蓄積していくことが 必要である.特に、正確な流出量を把握するため様々な 天候条件(特に出水時)や昼夜条件の動画撮影を行うこ とが求められる.この現地河川において水表面を撮影す



図-8 排水路の人工系ごみ判別例 (Case3,学習データ③, 2020年3月2日10:20)



図-9 Casel, 2, 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

表-3 Case3・学習データ③の種類判別精度

| ごみの種類 | 検証個数 | 正解個数 | 正解率 |
|--------|------|------|-----|
| ペットボトル | 5 | 1 | 20% |
| プラ袋 | 50 | 26 | 52% |
| 食品トレイ | 6 | 2 | 33% |
| 缶 | 1 | 0 | 0% |

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.ただし、倍率を上げすぎて、撮影範囲を狭く するとマクロプラごみの確認は易しくなるが、カメラ画 角内にマクロプラごみが写る個数が減ってしまうので、 動画の解像度や撮影範囲は工夫が必要である.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.

5. 結論

本論文では、深層学習に基づくマクロプラスチックご みの面積・種類判別手法を構築するため、平常時・出水 時河川におけるごみ画像を学習、深層学習には CNN と YOLO を用いた.得られた結論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 系ごみの一部の見逃すが, 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を検証した結果、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.

謝辞:本研究の一部は、(独)環境再生保全機構の環境 研究総合推進費(JPMEERF21356444)及び公益財団法人 河川財団の河川基金(2020-5211-041)によるものである. ここに記して謝意を表する.

参考文献

- Thompson, R. C., Olsen, Y., Mitchell, R. P., Davis, A., Rowland, S. J., John, A.W.G., McGonigle, D.and Russell, A. E.: Lost at sea: Where is all the plastic?, *Science*, Vol.34, 838p, 2004.
- Geyer, R., Jambeck, J. R. and Law, K. L.: Production, use, and fate of all plastics ever made, *Science Advances*, Vol.3, No. 7, e1700782, 2017.
- Schmidt, C., Krauth, T., Wagner, S.: Export of plastic debris by rivers into the sea, *Environmental Science & Technology*, Vol.55, pp.12246-12253, 2017.
- Siegfried, M., Koelmans, AA., Besseling, E., Kroeze, C.:Export of microplastics from land to sea. A modelling approach, *Water Research*, Vol.127, pp.249-257, 2017.
- 5) 外務省: 2015 G7 エルマウ・サミット首脳宣言(仮訳) (平成 27 年 6 月 8 日), http://www.mofa.go.jp/mofaj/ecm/ec /page4_001244.html(閲覧日: 2021 年 6 月 14 日).
- 外務省: 2017 G20 ハンブルク・サミット(G20 海 洋ごみ行動計画 英文)(平成 29 年 7 月 7,8 日), https://www.mofa.go.jp/mofaj/files/000272290.pdf (閲覧日: 2021 年 6 月 23 日).
- 環境省:大阪ブルー・オーシャン・ビジョン G20 大 阪首脳宣言(仮訳) (2019 年 6 月 28, 29 日), https://www.mofa.go.jp/mofaj/gaiko/g20/osaka19/jp/documents/final_g20_osaka_leaders_declaration.html
- Jambeck, J. R., Geyer, R., Wilcox, C., Siegler, T. R., Penyman, M., Andrady, A., Narayan, R. and Law, K.L.: Plastic waste inputs from land into the ocean, *Science*, Vol.347, Issue6223, pp.768-771, 2015.
- Kataoka, T., Nihei, Y., Kudou, K. and Hinata, H.: assessment of the sources and inflow processes of microplastics in the riverenvironmennts of Japan, *Environmenntal Pollution*, Vol.244,pp.958-965, 2019.

- 10) Nihei, Y., Yoshida, T., Kataoka, T. and Ogata, R.: High-Resolution Mapping of Japanese Microplastic and Macroplastic Emissions from the Land into the sea, *Water*, Vol.12, No.4, 951, 2020.
- Kataoka, T. and Nihei, Y.: Quantification of floating riverine macro-debris transport using an image processing approach, *Scientific Reports*, 10, 2198, 2020.
- 12) 吉田拓司・藤山朋樹・片岡智哉・緒方陸・二瓶泰雄: IP カメラ連続観測と画像解析手法に基づく複数出水時の河 川人工系ごみ輸送特性の比較,土木学会論文集 B1(水 工学), Vol.77, No.2, 2021(印刷中).
- 環境省図書館:海洋ごみ削減のための複数自治体等連携 による発生抑制対策等モデル事業等実施業務報告書(平 成31年度), pp.1-248, 2020, https://www2.env.go.jp/library/o pac/Holding list?rgtm=225184(閲覧日:2021年6月29日)
- 14) LeCun, Y., Bengio, Y. and Hinton, G.: Deep learning, *Nature*, Vol.521, pp. 436-444, 2015.
- 15) Yanming, G., Yu, L., Ard, O. Songyang, L. Song, W. and Micheal S, L.: Deep learning for visual understanding: A review, *Neurocomputing*, Vol.187, pp.27-48, 2016.
- 16) 藤吉弘亘,山下隆義:深層学習による画像認識,日本ロボット学会誌,Vol.35,NO.3,pp.180-185,2017.
- 17) Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A.:Going Deeper with Convolutons, *Proc.* of *IEEE* CVPR2015, 2015.
- 18) 中谷祐介,奥村素生,岩岡慶晃,西田修三:U-Net を用いた河川浮遊物の連続観測手法,土木学会論文 集 B1 (水工学), Vol.76, No.2, pp.I 997-I 1002, 2020.
- 19) LeCun, Y., Boser, B., Denker, J., Henderson, D., HowardR., Hubbard, W. and Jackel, L.:Backpropagation applied to handwritten zip code recognition, *Neural Computation*, Vol.1, No. 4, pp. 541-551, 1989.
- 20) Garcia-Garcia, A., Orts-Escolano, S., Oprea, S. O., Villena-Martinez, V., and Garcia-Rodriguez, J.: A Review on Deep Learning Techniques Applied to Semantic Segmentation, *arXiv preprint*, arXiv:1704.06857, 2017.
- 21) Joseph, R., Santosh, D., Ross, G. and Ali, F.: You Only Look Once: Unified, Real-Time Object Detection, *IEEE Conference on Computer Vision and Pattern Recogni*tionpp, pp.779-788, 2016.
- 22) 荒川クリーンエイド: 荒川クリーンエイド 2016 散乱 ごみ上位 15, https://cleanaid.jp/cleanaid/cleanaid_repo rt/all_report(閲覧日: 2021 年 6 月 25 日).

(Received June 30, 2021) (Accepted September 3, 2021)

EVALUATION OF AREA AND TYPES OF FLOATING MACROPLASTICS IN RIVERS DUE TO DEEP LEARNING

Hiro OTA, Tomoya KATAOKA, Takushi YOSHIDA and Yasuo NIHEI

Marine plastic wastes have been mostly originated from inland, and it is important to monitor macroplastics inflow into oceans via rivers. This study aims to develop a new image processing to capture the area and types of macroplastics with deep learning. The learning data for floating debris were collected with the field test under normal and flooding conditions. CNN and YOLO were applied to find the area and types of macroplastics. The results indicated that the CNN and YOLO can capture acceptably the area and types of macroplastics in normal flow condition. It is noted that add of the learning data under flooding conditions can greatly improve the accuracy of distinguishing the types of macroplastics by YOLO.