



Deep Learning Model for Evaluation of Area and Types of Floating Macroplastics in Rivers



Deep Learning Model for Evaluation of Area and Types of Floating Macroplastics in Rivers

Hiro Ota, Tomoya Kataoka, Takushi Yoshida, Yasuo Nihei
Tokyo University of Science, Department of Civil Engineering



1. Introduction

In recent years, the pollution of the rivers with plastic wastes has become a global environmental problem, and it is considered to be a serious problem (Kawano et al., 2017). While information of plastic wastes floating in rivers is quite scarce, there is a need to understand the distribution pattern of plastic wastes and to estimate the amount of plastic wastes floating in rivers and to estimate the amount of plastic wastes floating in rivers. In this study, a deep learning model is proposed to evaluate the area and types of floating macroplastics in rivers under a low flow condition.

3. Results and discussion for river data in a low flow condition

3.1 Accuracy of existing area of floating plastics

Figure 1 shows the result of the accuracy of the existing area of floating plastics in rivers. The accuracy of the existing area of floating plastics in rivers is 0.75. The accuracy of the existing area of floating plastics in rivers is 0.75. The accuracy of the existing area of floating plastics in rivers is 0.75.

4. Application to macro-plastic debris detection in rivers under flood

4.1 Debris of plastic wastes

This paper proposes for application of the deep learning model (DL) which is trained by recognizing types of macroplastic debris in rivers in a river under a flood condition. The accuracy of the deep learning model is 0.85. The accuracy of the deep learning model is 0.85.

2. Methods for collecting and analyzing debris data in a river under normal flow

2.1 Area evaluation of plastic wastes

In order to evaluate the area and number of floating and subsiding debris in rivers, an investigation of debris in rivers was conducted. The investigation was conducted in the area of the river in the city of Tokyo. The investigation was conducted in the area of the river in the city of Tokyo. The investigation was conducted in the area of the river in the city of Tokyo.

5. CONCLUSIONS

In this paper, for macroplastic debris detection in rivers under a low flow condition, a deep learning model (DL) was trained by recognizing types of macroplastic debris in rivers in a river under a low flow condition. The accuracy of the deep learning model is 0.75. The accuracy of the deep learning model is 0.75.

Thank you for your watching!

ABSTRACT CONTACT ADDRESS DETAILED CONTENT

Hiro Ota, Tomoya Kataoka, Takushi Yoshida, Yasuo Nihei

Tokyo University of Science, Department of Civil Engineering



PRESENTED AT:

AGU FALL MEETING
Chicago, IL & Online Everywhere
12–16 December 2022

SCIENCE LEADS THE FUTURE



1. INTRODUCTION

In recent years, the pollution of the oceans with plastic waste has become a global environmental problem, and its impact on ecosystems has become apparent (Schmidt et al., 2017). While international efforts are underway, 2019 the Osaka Blue Ocean Vision of the G20 declared that the discharge of plastic waste into the ocean will be reduced to practically zero in 2050. Since a large percentage of marine plastic debris originates from inland (Jambeck et al., 2015), it is extremely important to understand how much plastic debris is discharged from rivers. In the case of microplastics (plastic fragments less than 5 mm in size), measurement methods have been established to some extent, and these fragments have been monitored in many rivers in Japan (Nihei et al., 2020). In contrast, there are very few data on macroplastics (plastics larger than 5 mm) because of the lack of established measurement methods. On the other hand, Kataoka and Nihei (2020) have recently developed an image analysis method (RIAD, River Image Analysis for Debris flux) to monitor the amounts of debris transported in rivers by using the color difference between the surface of the river water and floating debris. The target of this RIAD is the entire river debris, which consists of artificial debris such as plastic debris and natural debris such as vegetation, and the discrimination (binarization) between the water surface and the entire river debris is performed by setting the threshold value of the color difference value. In addition, Yoshida et al. (2021) have set two thresholds to discriminate between the water surface, artificial debris, and natural debris (trilateration). Although the RIAD has proven to be useful to a certain extent, it is necessary to set the threshold for recognizing artificial and natural debris for each river site, and it is impossible to discriminate the types of plastic products at present, so new analysis techniques are needed.

Deep learning, which has made remarkable progress in recent years, is useful for this type of image analysis. Deep learning is a method for automatically learning features from a large amount of data and making predictions using a neural network modeled on the human brain's neural circuits (LeCun et al., 2015). When this deep learning is applied to the field of imaging, it can automatically learn the features of a target object and identify its location and type. Although deep learning has also been applied to river environment monitoring, there are no examples of its application to macroplastic debris in rivers.

The purpose of this study is to develop a method for calculating the area and discriminating the types of macroplastic debris in rivers based on deep learning as an alternative image analysis method to RIAD. For this purpose, we first took images of plastic debris floating in an actual river under normal conditions and used them as training and validation data for deep learning. As a method for estimating the area of plastic debris, we use "Semantic Segmentation" based on "Convolutional Neural Network (CNN) (LeCun et al., 1989)", which is often used for deep learning of images. In addition, YOLO (You Only Look Once) (Joseph et al., 2016), one of the object detection models, is used as the type-discrimination method. In addition, the applicability of the deep learning model developed in this study is verified using images of the water surface during flood conditions in rivers. This paper is a part of Ota et al.(2021).

2. METHODS FOR COLLECTING AND ANALYZING DEBRIS DATA IN A RIVER UNDER NORMAL FLOW

2.1 Data collection of plastic waste

In order to collect various types and numbers of training and prediction data for deep learning, we photographed artificial and natural debris, including plastic, floating on the surface of real river water under a normal flow condition. The observation site was Kati Bridge on the Ohori River in Kashiwa City, Chiba Prefecture, Japan (Figure 1). The date and time of the observation were September 17, 2020 from 10:00 to 16:00, and the flow condition was normal. At the site, 3 digital video cameras (HC-WX990M, Panasonic) were installed vertically downward on the parapet of the bridge shown in Figure 2, and many debris prepared in advance were poured from the upstream side of the filming area, collected at the downstream side, and the scene was recorded by DV cameras. The obtained movies were divided into 1seconds and still images were created. The resolution of the images varies depending on the camera, but for the analysis described below, we used images taken with a range of 2.1 m x 1.1 m, 3840x2160 pixels (px) (= 0.055*0.051cm/px), and 4x magnification. Table 1 shows the debris used in this study. The natural debris includes 50 branches and leaves. The used debris was passed around 6 one by one, and its appearance was photographed. The smallest piece of debris was a cigarette butt (= 4.16 cm²).



Figure 1 Observation site of the Ohori River under a normal condition.




Figure 2 Collection images for floating debris in the river.

Table 1 Average debris area and number of images used for training and validation data (pink: plastic debris, light blue: non-plastic artificial debris, green: natural debris, colorless: water surface)

Type of debris	Area of debris[cm ²]	Number of images	Type of debris	Area of debris[cm ²]	Number of images
PET bottle	170	145	Can	95	35
Plastic container	192	80	Bottle	53	14
Plastic bag	355	49	Paper carton	162	3
Straw	15	49	Nature	10819	28
Food tray	242	47	Leaf	996	88
Cigarette butts	5	24	Water surface		11
Cigarette lighter	11	12	13 types, 585 images in total		

2.2 How to calculate the area of artificial debris by CNN

To calculate the area of debris floating on the water surface, we use semantic segmentation by CNN. Semantic segmentation is a method to identify objects by pixel units, and by using this method, we can detect artificial debris at each pixel and calculate the area. The procedure for analyzing the area of artificial debris using CNN is summarized in Fig. 3. First, as a preparation before the analysis, we prepare an image in an actual river and its answer image (the trash area 1 and others 0). Next, image features are extracted from the training images using a kernel, one of spatial filters, in the convolution layer. In the batch normalization after the convolution layer, the input values are normalized (mean 0, variance 1) to improve learning efficiency, and the activation function ELU (Exponential Linear Unit) is applied. In this paper, we use a simple CNN, but we plan to try more general U-net and other methods in the future. As data, we used 424 images for artificial and natural debris from the movies recorded at the Ohori River for training and 161 images (artificial 109 and natural 52) for verification (total 585 images, Table 1). In the same table, the number of images of each type of debris used is also listed. The number of images of the most frequently observed types of debris was increased in reference to the deposited debris in rivers (Arakawa Clean Aid, 2016). In order to reduce the load on the analysis, the resolution of the images was reduced from the original 3840×2160 pixels to 960×540 pixels for the analysis. In addition, to make the images suitable for learning and prediction, we cropped multiple images at 256×256 pixels. In order to compare the accuracy of calculating the area of artificial debris by CNN, we also calculated the area of debris by 2 thresholds (75 and 100) in the RIAD.

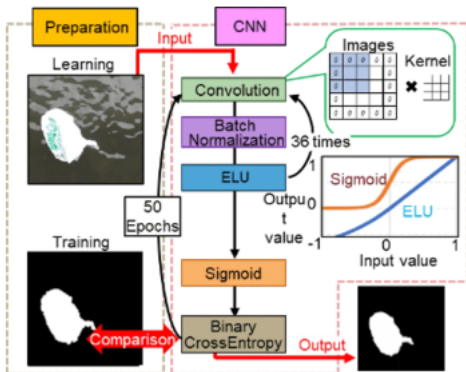


Figure 3 Analysis flow of artificial debris area using CNN (semantic segmentation)

2.3 Detection of plastic type using YOLO

YOLO is an object detection model that determines the location and type of an object. YOLO uses CNN to detect the center coordinates, width, height, and object type of a bounding box surrounding the object to be detected and divides the image into several grids for fast detection in real time. We used the latest version of YOLOv5 as the model and implemented it on Google Colaboratory. To classify debris, we created models for the following 3cases: Case 1: artificial and natural debris, Case 2: plastic, non-plastic artificial, and natural debris, and Case 3: 12 types of debris shown in Table 1. In 3 cases, the water surface was included in the analysis. For the training and prediction data, we used the 585 images taken at the Ohori River under normal conditions as well as the CNN, and the types of debris and the number of prepared images are shown in Table 1. The image size is 960x540 pixels. The answer images were tagged with the objects in the image by type using VOTT software.

3. RESULTS AND DISCUSSION FOR RIVER DATA IN A LOW FLOW CONDITION

3.1 Accuracy for calculating area of artificial debris

In order to examine the accuracy of calculating the area of debris by CNN, Figure 4 shows the results of calculating the area of plastic bags and PET bottles by using CNN and RIAD with the original images. In the analysis results, plastic debris and others are shown in white and black colors, respectively. In the RIAD, the threshold of plastic waste discrimination is set as 75 and 100. First, CNN was able to reproduce most of the plastic bags and PET bottles, but some parts of the PET bottles were missed. IN contrast, the RIAD overestimated the area of debris because white color is scattered in the area other than the plastic bags and PET bottles when the threshold is set to be 75. On the other hand, the CNN with threshold value of 100 missed a part of the plastic bag and does not reproduce the PET bottle at all. Next, we compare the accuracy of area calculation quantitatively. We calculate TP (ratio of pixels that debris could be estimated as debris), FP (ratio of pixels that was predicted to be debris but was mistaken), and FN (the number of pixels where debris was predicted not to be debris but was mistaken), which are used to evaluate the accuracy of deep learning, calculate the following 2 indices (IoU and missing rate).

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

$$Missing\ rate = FN / (TP + FN) \quad [2]$$

2 indices (IoU and missing rate) obtained for the analysis results of CNN and RIAD are shown in Figure 5. From this, the average value of IoU is 0.75 for CNN, but 0.22 and 0.15 for RIAD with the thresholds of 75 and 100, respectively. It means that the CNN analysis is more accurate than the RIAD. As for the mean value of missing rate, which should be low, the relationship is CNN < RIAD (threshold 75) < RIAD (threshold 100). The mean value of IoU for CNN is 0.75, which means that there is a prediction error of 25%. This error corresponds to the mean value of missing rate (=0.22), which reflects the fact that a part of the PET bottle was missed, as shown in Figure 4. These results indicate that the CNN is a more accurate method for calculating the area of debris than the RIAD.




Figure 4 Examples of detection results of plastic area using CNN and RIAD with threshold of 75 and 100 (White: plastic, Black: other).

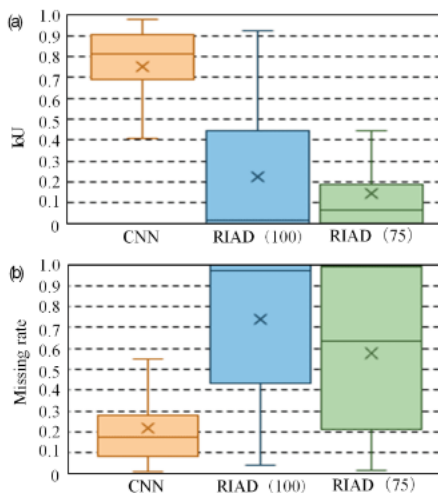


Figure 5 Comparison of area calculation accuracy between CNN and RIAD ((a) IoU, (b) Missing rate)

3.2 Accuracy for identifying plastic types using YOLO

Figure 6 shows the results of Case 3 as an example of the discrimination of debris types by YOLO. It can be seen that in the Case 3, the debris are surrounded by a rectangular area and the type of debris can be accurately identified. The accuracy (= number of correct answers / number of verification) was 88.5, 83.6, and 61.0 % for Cases 1, 2, and 3, respectively. It can be seen that the more detailed the classification of the debris, the lower the accuracy. The classification of natural and artificial debris (Case 1) and the classification of the presence or absence of plastic (Case 2) are generally good. Looking at the percentage of accuracy in Case 3 for each type of debris (Table 2), the accuracy for bundles and branches of natural debris is low, but the accuracy for the artificial debris is generally high. As shown above, the YOLO is generally able to distinguish among various debris.




Figure 6 Example of debris type discrimination in Case 3 of the YOLO (Left: PET bottle, Right: food tray)

In Case 3, we examined the dependence of the accuracy on the number of training data and the area of debris in order to investigate the reason why the accuracy decreased for some types of artificial debris as shown in Figure 7. Figure 7 (a) shows that the accuracy improves up to about 50 data but saturate to about 80% above that number. However, there are some variations in the accuracy (e.g., a triangle and a circle in the figures) even for the same number of learning data.

One of the factors is the debris area (Figure 7(b)), and the accuracy decreases when the debris area is too small (<100 cm²) or too large (>10,000 cm²). The former may be due to the problem of image resolution, and the latter may be due to the fact that the rectangular frame could not be set because it was too large compared to the image size. In the future, we will increase the number of training images as well, it is necessary to improve the accuracy of YOLO type discrimination by setting the appropriate resolution and angle of view size.

Table 2 Discrimination accuracy for each type of debris in Case3 of the YOLO.

Type of debris	Number of verifications	Accuracy	Type of debris	Number of verifications	Accuracy
PET bottle	14	71%	Can	4	75%
Plastic container	6	83%	Bottle	4	25%
Plastic bag	2	50%	Paper carton	1	0%
Straw	2	100%	Nature	10	20%
Food tray	4	75%	Leaf	8	88%
Cigarette butts	2	50%	Water surface	1	100%
Cigarette lighter	1	0%			




Figure 7 Examination of factors for reducing the accuracy of the YOLO.
 ((a) number of learning images, (b) debris area)

4. APPLICATION TO MACRO-PLASTIC DEBRIS DETECTION IN RIVERS UNDER FLOOD

4.1 Outline of detection method

In this paper, we examine the applicability of the deep learning model YOLO, which is a method for discriminating types of macroplastic debris in rivers, to actual river monitoring during flood. The target site is a drainage channel in the Tenpaku River basin flowing through Yokkaichi City, Mie Prefecture, Japan, where the authors conducted field observations¹²⁾. In this study, 137 images including debris were selected as the training and validation images from the videos taken continuously from August 2019 to September 2020, including floods. We prepared three datasets which are A) 585 images of the Ohori River, B) 87 images of drainage channels, and C) 672 images of both A) and B), to examine the influence of the training dataset on the accuracy of the YOLO. The types of debris discriminated were Case 1 to 3 as described above, and the accuracy of the model was verified on 50 images of the drainage channel (62 pieces of artificial debris in total).

4.2 Results and issues

As an example of discrimination of macro plastic debris floating in a drainage channel, Figure 8 shows results of Case 3 using training the dataset-A. As shown in Figure 8, two plastic bags floating in the drainage channel can be discriminated during the daytime. Although the validation images included nighttime images, we were able to discriminate macro plastic debris. Figure 9 shows the accuracy of the YOLO with the training dataset-A, B and C. The accuracy is the ratio of the number of pieces for which we were able to determine the type of debris to the number of pieces for verification. It can be seen that the accuracy is in the relationship of dataset-A < dataset-B < dataset-C in all 3 cases. This indicates that the images of the local river (here, the drainage channel) are more important than the images of the other river (here, the Ohori River), and that increasing the number of images by mixing both of them greatly contributes to improving the accuracy of debris identification. Although the overall accuracy decreases as the number of debris types increases (i.e., Case 1 > Case 2 > Case 3), the accuracy for Case 3 using the training dataset-C is 47 %, which is slightly lower than the result for the Ohori River under normal conditions. Looking at the accuracy for each type of debris in this case (Table 3), the accuracy for plastic bags, which are the largest number among debris, is over 50%, while the accuracy for plastic bottles, which are the smallest number among debris, is also low. It was also confirmed that the YOLO did not misrecognize bubbles and waves as debris, even though they were observed in the images taken under floods. From the above, the YOLO can improve the accuracy of macroplastic debris discrimination by increasing the training data and incorporating images of the target sites. For this, it is necessary to collect and accumulate images mainly of macroplastic debris scattered in rivers. In particular, it is necessary to take video images under various weather conditions (especially flood) and day/night conditions in order to accurately grasp the debris transport during whole flood. When photographing the surface of the water in this local river, the resolution should be high enough to identify major macroplastic debris such as plastic bags and bottles. However, if the magnification is increased too much and the shooting range is narrowed, it will be easier to identify macroplastic debris, but the number of macroplastic debris within the camera's angle of view will decrease. In addition, it is unclear how many and what kind of debris images should be learned in order to improve the accuracy of the YOLO model, and this is an issue for further study.



Figure 8 Example of artificial debris discrimination in the drainage channel in Case3 with the dataset-C. (Photo taken at 10:20, March 2, 2020)




Figure 9 Comparison of accuracy of artificial debris with the training dataset-A, B and C in 3 cases.

Table 3 Accuracy for plastic-type discrimination with the training dataset-C in Case 3.

Type of debris	Number of verifications	Number of correct	Accuracy
PET bottles	5	1	20%
Plastic bag	50	26	52%
Food tray	6	2	33%
Can	1	0	0%

5. CONCLUSIONS

In this paper, in order to construct a deep learning-based method for discriminating the area and type of macroplastics, debris images in normal and emergent rivers are trained, and CNN and YOLO are used for deep learning. The conclusions obtained are as follows.

- 1) For a low-flow condition, the CNN may be a more accurate method for calculating the debris area than the RIAD, although it missed some of the artificial debris floating on the water surface. Similarly, the accuracy of the YOLO in discriminating debris types was generally high for anthropogenic debris, although it was low for bundles and branches of natural debris.
- 2) As a result of verifying the applicability of the YOLO to actual rivers during floods, the discrimination accuracy was improved by increasing the number of training data and incorporating images of the target site.

Thank you for your watching!

ABSTRACT

In recent years, plastic debris pollution in the ocean has become a global environmental problem, and its impact on ecosystems has become apparent. Since most of the marine plastic debris originates from terrestrial sources, it is important to measure the macroplastics (>5 mm) debris that enters the ocean via rivers.

The purpose of this study is to develop a new image analysis method for determining the area and type of macroplastics debris floating in rivers based on deep learning.

In order to create the training data, various types of artificial and natural debris floating on the surface of water in a normal river were photographed (585 images in total). To estimate the area of plastic debris, we used Semantic Segmentation based on CNN, which is often used for deep learning of images. The results were compared with RIAD (River Image Analysis for Debris flux). In addition, YOLO, one of the object detection models, is used as a type discrimination method. In addition, the applicability of the deep learning model developed in this study is verified using images of the surface of river water during an actual water outflow.

The area estimation method using CNN showed better results than RIAD in two indices, IoU and miss rate, indicating that it is a highly accurate method for calculating the area of debris, although some misses remain.

In the case of type discrimination by YOLO, the correct answer rate ($= \text{number of correct answers} / \text{number of verified answers}$) was 61.0%, indicating that the discrimination was generally successful. The percentage of correct answers for bundles and branches of natural types was low, but the percentage of correct answers for artificial types of litter was generally high.

As a result of applying YOLO to the river at the time of runoff, the accuracy of the type identification of plastic litter was greatly improved by adding the litter images taken at the site to the training data, and the correctness rate of the type identification was 47%.

In the future, it is necessary to collect and accumulate images of macroplastics debris, which is widely scattered in rivers. For this purpose, it is necessary to take video images under various weather conditions and day/night conditions, but it is unclear how many images (number of images) and what kind of litter images should be trained, and this is an issue for further study.

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.chime-u.ac.jp

³正会員 八千代エンジニアリング(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 learning, 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⁷⁾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 Analysis

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^{12)・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 Learning)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




図-1 平常時河川の観測サイト (千葉県大堀川)




図-2 河川浮遊ごみ撮影状況

クロプラス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枚		

た動画を 1 秒毎に分割し静止面を作成した。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、Binary Cross Entropy 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

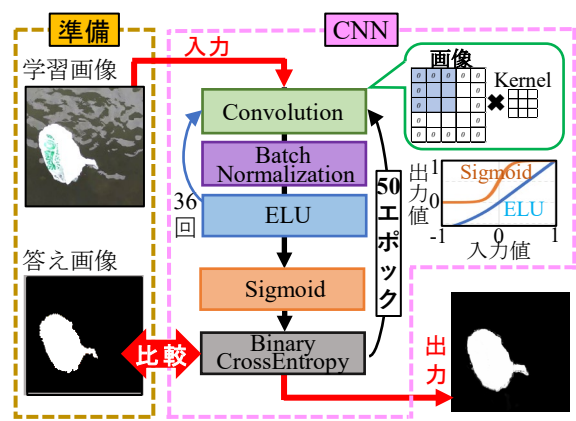


図-3 CNN (セマンティックセグメンテーション) による人工系ごみ面積の解析フロー

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²²⁾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れ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^{11)・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 を使い、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




図-4 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)

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。

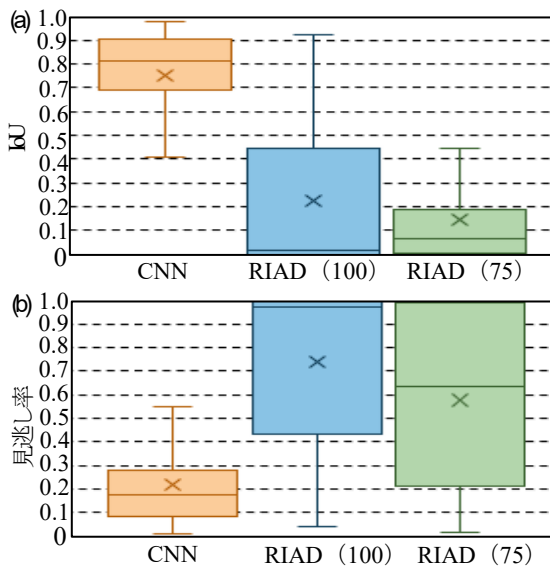


図-5 CNNとRIADの面積算出精度の比較 (a)IoU, (b)見逃し率

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

$$見逃し率 = FN / (TP + FN) \quad (1b)$$

CNNとRIADの解析結果に関して得られた2指標 (IoU, 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IoU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画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Case1～3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 Case1, 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。

参考文献

- 1) 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.
- 2) 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.
- 3) Schmidt, C., Krauth, T., Wagner, S.: Export of plastic debris by rivers into the sea, *Environmental Science & Technology*, Vol.55, pp.12246- 12253, 2017.
- 4) 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）。
- 6) 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）。
- 7) 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
- 8) Jambeck, J. R., Geyer, R., Wilcox, C., Siegler, T. R., Perelman, 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.
- 9) Kataoka, T., Nihei, Y., Kudou, K. and Hinata, H.: assessment of the sources and inflow processes of microplastics in the river environments of Japan, *Environmental 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.
- 11) 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)。
- 13) 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/opa/Holding_list?gtn=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., Howard R., Hubbard, W. and Jackel, L.: Backpropagation applied to handwritten zip code recognition, *Neural Cmpputation*, 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 Recognition*, 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.