

UAV を活用した河川巡視への人工知能の適用

矢原諒*・西山哲*・下野友裕**・吉岡小百合**・尾方浩平**

*岡山大学大学院環境生命科学研究科, **国際航業株式会社

1. はじめに

近年記録的な豪雨が多発しており、それに伴って水害も増加している¹⁾。平成30年7月豪雨や令和2年7月豪雨などは甚大な被害を及ぼした。これらの災害を未然に防止する、あるいは早期に発見するためにも、河川の状態を日常的に把握する河川巡視業務は重要度を増している状況にある。しかし、現在、河川巡視は巡視員の目視によって定性的な異常の把握がなされており、長大な堤防の巡視には多くの労力が費やされている。そこで本研究では、河川巡視の効率化手法としてカメラを搭載した UAV によって撮影された画像から人工知能を用いて投棄物を自動抽出する手法を検討した。

2. 人工知能による物体検出技術

人工知能は近年の技術発達が著しい分野であり、身近なところでも自動運転技術や画像検索技術などあらゆる分野で活躍している。なかでも物体検出技術は、社会インフラ点検へも展開が図られており、コンクリート構造物のひび割れ検出などの研究も盛んに行われている²⁾。

(1) 機械学習

機械学習とは人工知能の一種である。与えられたデータと指定された特徴量に対して機械が学習を行い、未知のデータに対しても分類や予測などのタスクを行うことができる。特徴量とは学習させたいデータに対して機械が学習できるように意味づけた数値のことであり、機械学習の特徴はその特徴量を人間が指定することができるため、結果の考察が比較的行きやすいことにある。本検証では学習モデルとして OpenCV の traincascade、特徴量として LBP 特長量を採用した。LBP 特長量とは ojala らによって開発された特徴量であり³⁾、各画素の輝度値の差からヒストグラムを作成しそれを特徴量とする。輝度値の差をとることから全体的な照度の差に強いという利点がある。

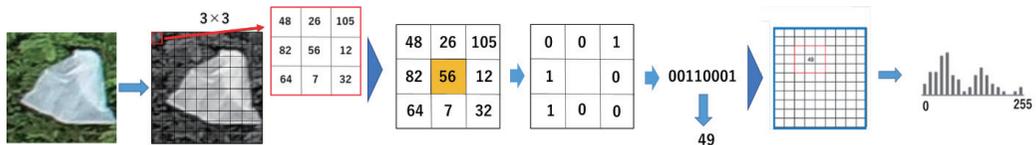


図 1 LBP 特長量抽出フロー

(2) 深層学習

深層学習とは機械学習の一種である。機械学習との大きな違いは、特徴量を人間が指定する必要がなく、機械が自ら適切な特徴量を判断し選択するという点にある。そのため中身がブラックボックス化しやすいが、高い精度を誇っており近年注目を集めている。その仕組みは従来から用いられたニューラルネットワークという人間のニューロンを模した学習方法を多層に組み合わせることにより、より複雑な問題に対しても学習することを可能にしている⁴⁾。本検証では深層学習手法として retinanet を用いた。retinanet は Focal loss と呼ばれる誤差関数を用いることで、クラス分類の際の不均衡を緩和することのできる学習モデルである⁵⁾。

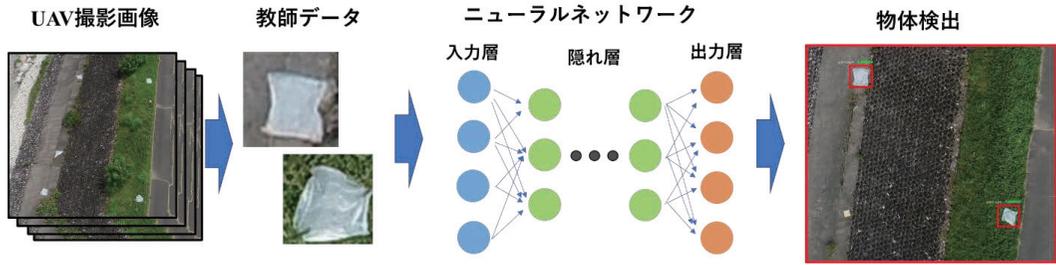


図 2 深層学習の学習フロー

3. 検証概要

(1) 検証手法

撮影は河川 A と河川 B の 2 か所である。対象河川には不法投棄物としてごみ袋を複数配置し、角度と高度を変化させながら撮影を行った。図 3 にそれぞれの河川におけるごみ袋の撮影事例を示す。その後、撮影画像からごみ袋に対してアノテーション作業を行い、機械に学習させた。教師データの仕様として河川 A の 30×30 ピクセル以上の画像のみ使用した。アノテーションを行ったごみ袋の枚数は 3166 枚である。そのうち深層学習では全画像を、機械学習では全画像を用いると結果が収束しなかったため学習枚数を減らし、最終的には 864 枚の教師データを学習させたのちに検証を行った。



図 3 対象物の撮影事例（左：河川 A，右：河川 B）

(2) 評価方法

検出結果において、機械が対象物を検出しない未検出や、分類器が対象物以外を検出してしまいう誤検出は少ないことが望ましく、これらはトレードオフの関係にある。そこでそれぞれの評価方法として適合率、再現率、そして総合的な検出精度の指標として F 値を用いた。具体的な算出方法として、得られた検出結果を以下の①から③に分けて計算を行った。

- ① TP・・・実際に存在する対象物を機械が正しく対象物であると判断した数
- ② FP・・・対象物以外を機械が間違っって対象物であると判断した数
- ③ FN・・・実際は対象物であるのに機械が間違っって対象物でないと判断した数

再現率は式(1)であらわされ、未検出の少なさの程度を表す値である。この値が大きければ画像内のごみ袋に対して、検出できなかったごみ袋が少ないことを表している。式(2)は適合率を表しており、適合率が高いほど誤検出が少ないことを表している。この二つをもとに本検証における精度を表す総合的な指標である F 値を求める。F 値はトレードオフの関係にある適合率と再現率の調和平均をもってあらわされる。

$$\text{再現率} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (1)$$

$$\text{適合率} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

$$\text{F 値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}} \quad (3)$$

(4) 地上解像度

撮影から得られた結果は角度と地上解像度ごとに整理した。地上解像度とはデジタル画像 1 画素が示す地上での距離のことであり、図 4 は地上解像度 2.0 cm, 3.0 cm, 4.0 cm のものを比較している。



図 4 撮影されたごみ袋の地上解像度ごとの例

4. 検証結果

4.1 河川 A での検出結果

(1) 検出精度

河川 A における高さや角度がそれぞれ異なる 17 枚の画像で検証を行った。F 値は機械学習の場合最大で 76%, 平均 40.0% で、深層学習の場合は平均 92.4% と深層学習のほうがより高い検出精度を得られた。機械学習では地上解像度の変化に弱く、高度や角度が変化するにつれ精度が著しく低下した。対して深層学習では高高度でもごみ袋を検出できた。図 5 に 60 度 125m (地上解像度 4.0cm) における深層学習の検出事例を示す。



図 5 深層学習による検出事例

(2) 輝度値による違い

図 6 は照度変化による F 値の変化を深層学習、機械学習で比較したものである。深層学習では F 値が 40% 程度低下しているのに対して、機械学習ではほとんど変化していない。このことから検出精度で見れば機械学習は深層学習と比べ高くないが、機械学習による検出結果は照度の差にロバストであることが確かめられた。図 7 に示すとおり、LBP 特長量は特定の画素に対してその周辺の輝度値の差を特徴量として識別しているため、画像全体の照度が低下してもその影響を受けにくい。このことから機械学習は特定の状況下において適切な特徴量を指定すれば相応の検出結果を得られると考えられる。

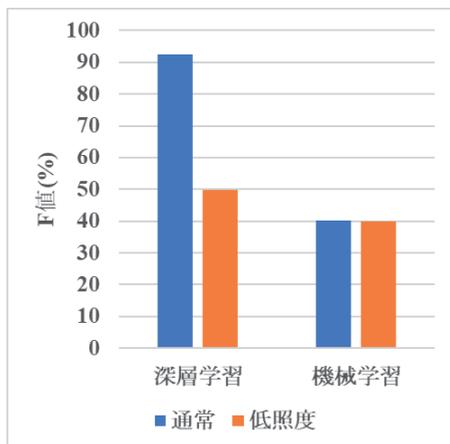


図 6 照度変化による F 値の比較

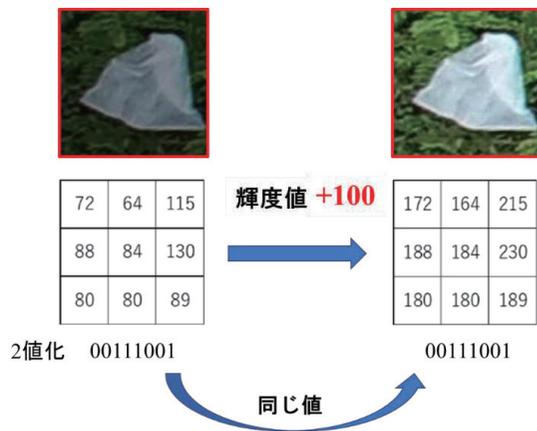


図 7 LBP 特長量の照度変化に対するロバスト性

4.2 深層学習での検証結果

精度が高かった深層学習に対して河川 B でも検証を行い, 検証画像を増やして角度, 解像度ごとに結果を整理したのが表 3 である. 概ねどの角度でも地上解像度が低下するにつれて F 値が下がる傾向が見られた. また, 河川 A での撮影画像を学習した機械を河川 B に適用した場合, 河川 A で検証を行った場合よりも検出精度が低下する. どちらの河川でも対象物は同じであるが, 植生の上に置かれていたものが多かった河川 A に対して, 河川 B は石の上に置かれているごみ袋が多かったため, その背景の変化から検出精度が低下したと考えられる.

表 1 パラメータごとの検出結果

			河川A			河川B		
			解像度 (cm)			解像度 (cm)		
			2.0	3.0	4.0	2.0	3.0	4.0
アングル	45度	検証データ枚数	24.0	23.0	22.0	16.0	17.0	14.0
		再現率	84.9	68.2	58.1	27.0	21.0	12.7
		適合率	86.3	78.1	83.6	83.9	80.9	71.7
		F値 (%)	85.6	72.8	68.5	40.9	33.3	21.6
	60度	検証データ枚数	19.0	19.0	20.0	23.0	15.0	14.0
		再現率	97.3	73.1	78.9	27.9	22.1	22.6
		適合率	91.3	89.8	79.8	69.9	78.7	84.3
		F値 (%)	94.2	80.6	78.9	39.8	34.5	35.7
	75度	検証データ枚数	24.0	28.0	19.0	17.0	22.0	21.0
		再現率	88.5	75.0	75.6	41.2	29.9	12.2
		適合率	76.2	81.6	86.7	79.0	78.2	84.3
		F値 (%)	81.9	78.1	80.7	54.1	43.3	21.3

5. まとめ

本研究は UAV を活用した河川巡視への人工知能の適用性を検討した. 以下に得られた結果をまとめる.

- ・河川巡視の効率化に関して, 深層学習は機械学習と比較して高い検出精度が期待できる.
- ・機械学習は特徴量を指定できるため, 低照度下など特定状況下における検出で効果が期待できる.
- ・地上解像度や教師データと検証画像間での背景の違いの影響を受け検出精度は低下する.

今後について, 高高度で広い範囲を撮影した画像から検出ができればより効率化につながるため, 地上解像度に影響されない物体検出の検討, 様々な河川に対応できる汎用性の高い機械の作成を目指す.

謝辞

本研究は国土交通省の革新的河川技術プロジェクトの一環として実施し, 国土交通省水管理・国土保全局には多くのご支援をいただきました. ここに感謝申し上げます.

参考文献

- (1) 国土交通省水管理・国土保全局「水害レポート 2019」, 2019.
- (2) Pang C. and Atsushi I, Crack detection from image using random forest, Journal of JSCE, Vol.71, No.2, p.I_1-I_8, 2015.
- (3) Ojala T. Pietikäinen M. and Harwood D., A comparative study of texture measures with classification based on featured distributions Pattern Recognition, Vol. 29, Issue 1, pp 51-59.2020, 1996.
- (4) 岡谷貴之, 深層学習について, 日本ロボット学会誌, 33 巻, 2 号, p92-96, 2015.
- (5) Tsung L. Priya G. Ross G. Kaiming H., Piotr D. Focal Loss for Dense Object Detection, Computer Vision and Pattern Recognition, ICCV, 2017.