

自律飛行 UAV と深層学習を活用した河川監視技術の開発

藤井 純一郎† 高橋 悠太† 吉田 龍人† 天方 匡純†

八千代エンジニアリング株式会社 技術開発研究所†

1. 背景・目的

自律飛行のための UAV 運航管理技術や異常検知のための AI 解析技術などの要素技術が進展し、これらを活用することで河川監視の効率化・高度化が期待されている。UAV 空撮画像をもとに自動で河川監視項目を検出するには深層学習の適用が有望であるが、そのために必要な教師データが不足することが課題であった。

本研究では日常監視において既存の河川監視記録と新規に取得する UAV 空撮データを組合せて深層学習を適用し、河川監視項目の自動検出を試行した結果について報告する。また出水後監視において UAV 空撮データから領域を分割し、河道状態の自動検出を試行した結果を報告する。

2. 河川監視のユースケース

現状の目視による河川監視業務¹⁾のうち、自律飛行 UAV と深層学習で自動化が可能なユースケースとして下記の2つを抽出し、それぞれの自動化手法に対して開発を行った。

2.1. ObjectDetectionによる違法行為発見

日常監視で行う不法投棄・不法工作物などの違法行為を発見し記録するもの

2.2. SemanticSegmentationによる河道状態把握

出水後監視で行う河岸浸食・砂州堆積などの河道の状態変化を把握するもの

3. ObjectDetectionによる違法行為発見

本研究では違法行為の中でも記録数が多く、自動化の効果が高い不法投棄を対象とした。

3.1. 空撮画像の不法投棄検出モデルの構築

不法投棄の空撮画像は入手できなかったため、本研究で疑似の不法投棄を設置して空撮実験を行い、不法投棄の空撮画像を収集した。

これらの空撮画像に対して不法投棄の領域をアノテーションし、不法投棄の周辺を 640×480 [pixel] でランダムクロップ (図 1 内橙破線) して 300 枚の教師画像を得た。



図 1. 空撮画像と教師画像クロッピング例

Object Detection のユースケースではフライト中のリアルタイム推論は求められないが、フライト後は即時に違法行為を検出する必要がある。そのため比較的計算量が少なく高精度な Faster R-CNN²⁾を採用した。

学習においては教師画像のうち 280 枚を使用し、 224×224 [pixel] に分割した RGB 画像を入力とした。特徴量の抽出を効率化するため、バックボーンには事前学習済み ResNet50 を使用した。勾配計算は SGDM (Stochastic Gradient Descent with Momentum: モーメンタム項付き確率的勾配降下法)、ミニバッチサイズは 2、学習率は 0.0001、学習エポック数を 10 に固定して行った。本モデルをベンチマークモデルとする。

ベンチマークモデルでのテストデータの推論結果の例を図 3 に示す。教師画像の枚数が限られるため未検出が発生していることがわかる。

3.2. 地上画像の追加による精度向上

ベンチマークモデルの教師画像は枚数が限られるため、実験環境以外の河川への適用は実用的でない。そこで空撮画像に加えて、既存の目視による河川監視で撮影された地上画像を加えて精度向上を試みた。

地上画像は人が手作業で撮影した画像のため、撮影距離や角度はまちまちである。中には近接で撮影したものもあるため、地上画像を無作為に教師画像として利用すると精度が低下する。そこで本研究では Bounding Box の面積割合 (BB 占有率) が空撮画像と同程度となる地上画像を選出して改良モデルの学習を行った。

Development of river monitoring technology using autonomous flight UAV and deep learning

†Fujii Junichiro, Takahashi Yuta, Yoshida Ryuto, Amakata Masazumi • Yachiyo Engineering Co., Ltd.




図 2. 地上画像

地上画像を追加して学習したモデルでの推論結果の例を図 3 に示す。空撮画像のみで学習したモデルより未検出が減っている。空撮画像の持つ特徴量のみでは検知困難な対象物を、地上画像により補完できていると考えられる。




図 3. 推論結果 (左: ベンチマーク 右: 改良モデル)

4. Semantic Segmentation による河道状態把握

出水後の巡視・点検では河川の安全性に関わる河岸浸食や流下能力の変化を把握する必要がある。本研究ではオルソフォトに対して河道領域の Semantic Segmentation を適用した。

4.1. 河道領域分類クラスの定義

河川監視で求められる領域分類の要件として以下を設定した。

- 低水路は砂州と水面の境界を正確に捉える
- 高水敷は樹木と草地を分けて把握する
- モデルの精度低下を防ぐため上記以外の微小な領域は分類しない

以上の方針に従い、本研究ではセグメンテーションの対象と色見本を表 1 の 5 クラスとした。

表 1. 河道領域分類クラスとカラーマップ

名称	色見本
低水路水面	青
低水路砂州・高水敷裸地	白
高水敷樹木	緑
高水敷草地・裸地	黄緑
道路・橋梁・護岸	黄

4.2. 河道領域分類モデルの構築

クラス定義に従って、200 枚の画像に対して目

視判別によってアノテーションを実施し、それを 500×500 [pixel] に分割した RGB 画像を教師画像とした。Semantic Segmentation モデルは 2018 年に提案され、高精度なセグメンテーションを実現した Deeplab-v3³⁾ を採用した。基盤のネットワーク構造は Xception を使い、Pascal VOC データセットでの学習済みモデルを用いて転移学習を行った。勾配計算は SGDM、ミニバッチサイズは 15、学習率は 0.0001、学習エポック数を 20000 とした。学習結果として全クラスの IoU が 0.8 を上回るモデルを得ることができた。

学習で用いていないテストデータに対する推論結果の例を図 4 に示す。水面と護岸の境界線や砂州・樹木の領域を概ね正しく捉えていることがわかる。従って出水前後で本モデルを適用することで、河川監視に必要な河岸浸食や砂州堆積の変化を把握することが可能と考えられる。




図 4. 領域分類結果

5. まとめ

本研究では自律飛行 UAV による空撮画像に対して深層学習を適用することにより、河川監視を自動化する実践的な手法を提案し、日常監視と出水後監視の 2 つのユースケースを設定して実験を行った。

日常監視においては Object Detection を適用し、教師画像に地上撮影画像を混在させることで、限られた空撮画像から河川監視項目の検出を行える可能性が示された。出水後監視においては Semantic Segmentation を適用し、河道の領域変化を検出できることを示した。

今後は複数河川・複数時期の UAV 空撮画像に対して 2 つのユースケースの実証を行い、河川監視の実現場への適用を図っていきたい。

<参考文献>

- 1) 国土交通省：河川砂防技術基準 維持管理編 (河川編)，2015。
- 2) Ren, S., He, K., Girshick, R. and Sun, J.: Faster R-CNN: Towards real-time object detection with region proposal networks, NIPS, 2015.
- 3) Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F. and Adam, H.: Encoder-decoder with atrous separable convolution for semantic image segmentation, ECCV, 2018.