

複数河川での UAV 空撮画像内不法投棄検知の可能性検証

八千代エンジニアリング 正会員 ○高橋 悠太
正会員 藤井 純一郎
正会員 天方 匡純

1. 背景

我が国は多くの河川を有し、効率的な巡視のため、ドローン(UAV)とAIを用いた河川巡視の高度化が検討されている¹⁾。河川巡視は、多様な背景の中から、多様な対象を検出する必要がある。本研究では河川Aで空撮された不法投棄画像を学習したAIモデルに、河川Bで得られた画像を追加する転移学習後、それぞれの河川の画像に対する検知性能を評価する。

2. 実験概要

空撮画像の他に、比較として地上画像(地上で撮影された不法投棄画像例)を図-1に示す。赤枠は不法投棄を示す。空撮画像は地上画像に対し、画像サイズに対する不法投棄の割合はごく僅かとわかる。学習効率低下を避けるため、地上画像を参考に、地上画像に最も多い640×480[pixel]程度(図-1(a)内橙破線)に切り出して使用する。空撮画像は、疑似不法投棄の上空から、角度を変えて撮影した。検出モデルはFaster R-CNN²⁾を用いる。特徴量抽出を効率化するため、ImageNet事前学習済みのResNet50³⁾を使用し、抽出層は40層のReluとした。入力サイズが224×224のRGB画像を用いた。学習にはMATLAB 2020a環境を利用し、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)⁴⁾、ミニバッチサイズは2、学習率は0.0001、学習エポック回数は10とした。

3. 結果と考察

河川Aの空撮画像のみ(17016枚)学習したモデル(Case.1)による河川A未学習データ(6807枚)に対する推論結果を図-2、図-3に示す。図-2はPR曲線を示す。図-3は推論例を示し、黄色枠は推論された検知対象範囲、数字がAIの推論結果に対する自信度を示す。平均Precisionは0.89、図-3をみても、比較的良好な結果となった。左上に写っている不法投棄は今回アノテーションを行っていないので、検知できなくとも問題ない。実際は、連続的に撮影した画像に対して推論を実行するため、アノテーションを一部省略することも問題ない。次に、Case.1のモデルで河川Bのデータ(4550枚)を転移学習し、河川B未学習データ(2265枚)を推論した結果のPR曲線を図-5に示す(Case.2)。評価学習用に758枚を用いた。河川Bのデータには、河川Aにはない複雑な不法投棄やコーンなどの人工物、人・船などが含まれている。学習はCase.1と同条件で行った。PRは0.54と、図-5、図-6に河川Aのデータに対する推論結果を示す(Case.3)。平均Precisionは0.22と大きく低下し、自信度も低下していることが分かる。これらは両河川のデータをうまく学習できていないことを示していると考えられる。図-7(a)-(c)にはCase.2の推論結果の例を示す。河川Aではなかった複雑な不法投棄や人・船舶などが検知できている。また図-7(d),(e)に



(a) 空撮画像 (3840×2160 [pixel])



(b) 地上画像 (640×480 [pixel])

図-1 空撮画像と地上画像

キーワード ドローン(UAV) 河川巡視 AI 対象物検知 複数河川

連絡先 〒111-8648 東京都台東区浅草橋 5-20-8 CSタワー3F 技術創発研究所 高橋悠太 TEL 03-5822-2903




図-2 Case.1 の PR 曲線



図-3 Case.1 での推論例

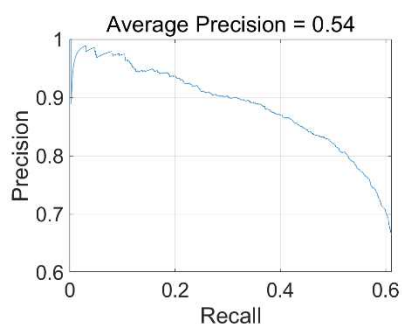


図-4 Case.2 の PR 曲線





図-5 Case.3 の PR 曲線



図-6 Case.3 での推論例



(a) 不法投棄




(b) 人



(c) 船舶



(d) コーン(成功)



(e) コーン(失敗)

図-7 Case.2 での推論例

同様の対象(コーン)に対し、検知が成功・失敗している推論結果を示す。背景によって、検知結果に違いが生じていると考えられる。これらの結果から、対象画像数のバランス調整などによる改善が考えられる。

図-3、図-6、図-7を併せて比較すると、Case.3において、より対象をタイトに捉える結果となった。河川Bのデータは河川Aと比較して、対象枠が対象に触れるようアノテーションされていることから、転移学習の効果が生じたと考えられる。

4. まとめ

複数河川で得られたドローン空撮画像をAIで学習し、不法投棄が検知可能か、性能検証を行った。結果として、単一河川で学習したモデルであれば、性能が発揮されることを確認できた。ただし、学習の順序、データのバランス、ハイパーパラメータの調整等で

河川の違いに関わらず学習できる可能性もあり、今後パラメータを変更して学習を試みる。あるいは、評価学習データに河川Aのデータを加えるなどして交差学習を行い、結果を比較評価する。

参考文献

- 1) 高橋悠太, 藤井純一郎, 天方匡純, 山下隆義: UAVと画像認識AIによる河川巡視を補う地上画像の特徴量とその利用法検討, AI・データサイエンス論文集, 第1巻, J1号, pp.580-587, 2020.
- 2) S. Ren, K. He, R. Girshick, and J. Sun, Faster R-CNN: Towards real-time object detection with region proposal networks, NIPS, 2015.
- 3) He, K., Zhang, X., Ren, S. and Sun., J.: Deep residual learning for image recognition, Computer Vision and Pattern Recognition (CVPR), 2016.
- 4) Bottou, L.: Large-Scale Machine Learning with Stochastic Gradient Descent, Proceedings of the 19th International Conference on Computational Statistics (COMPSTAT' 2010), pp. 177-187, 2010.