

ドローン画像を用いた深層学習による災害時の道路上の車両抽出に関する研究

香川大学 学生会員 ○妹尾大輝, 非会員 和田光真, 正会員 野々村敦子, フェロー 吉田秀典

1. 研究背景

近年, 地球規模の気候変動に起因した大規模な災害が頻発している. 発災後における避難の判断や災害対応に役立てるため, 被災地の状況を可能な限り迅速に把握する必要がある. 現在, 災害直後に人工衛星やドローンによる被災地観測が行われ, 被災地の状況を視覚的に確認することが容易になっている. しかし, 人工衛星は撮影頻度の観点から災害直後に被災地を必ず撮影できるとは限らず, また広範囲を観測可能であるが解像度の関係で狭い道路の状況を判別することは困難である. 一方で, ドローンは発災直後に被災地で特定箇所を重点的に撮影でき, 高解像度な画像を即座に入手することが可能である. そこで, 本研究ではドローン画像に着目し, ドローンにより撮影された高解像度な画像と AI を組み合わせることにより, 災害時における道路の閉鎖状況を把握することを目的とする.

2. 物体抽出モデル

2-1. YOLO

本研究では, CNN を用いた物体抽出モデルにより道路上にある車両などを検知することで災害時における道路の閉鎖状況を判断する. CNN を用いた物体抽出手法として, リアルタイムでの物体抽出が可能である YOLO を採用した. YOLO は, 画像認識を回帰問題に落とし込み, 従前では独立した機能を持つ手法しか存在しなかった「画像の領域推定」と「分類」を同時に行うことができる. YOLO のアルゴリズムは一つの CNN で構成されており, そのシンプルさから処理時間の速さや汎化性能に優れている特徴がある. また, 導入が容易である点や, 抽出精度と演算負荷に応じて 4 つのモデルを選択できる点が利点として挙げられる. YOLO は, これまでに v1 から v5 までの計 5 つのバージョンが公表されており, バージョンが更新されるごとに高性能化している. 本研究では, 現時点で最も高性能となっている YOLOv5 を使用して物体抽出を行った.

2-2. 学習用画像データ

本研究では, 災害時の道路状況の把握のため, 車両を撮影したドローン画像を学習用データとして使用する. ドローン撮影は, 可視カメラと赤外カメラを搭載し, 4K の高解像度な画像も撮影することが可能な図 1 に示すドローンを使用した. ドローンは撮影条件に様々な制約があることから, それらを考慮し, 香川大学創造工学部の敷地内にある駐車場を撮影した. しかし, 図 2 の左側に示すようなドローンで撮影した画像のみでは画像に写る車両の数や大きさなどは大きく変化しないため, 抽出精度や使用画像枚数の観点から抽出モデルの作成には不十分であった. そこで, 図 2 の右側に示すような車両が撮影された画像を別途取得し, ドローン画像とそれらの画像を組み合わせることで抽出モデル作成を行った. 画像データ枚数はドローン画像が 64 枚, 別途取得した画像が 204 枚の計 268 枚であり, 画像サイズはドローン画像が 3040 pixels×4064 pixels, 別途取得した画像が 3104 pixels×4672 pixels である. YOLO では, 学習の際に用いられるストライドの最大値が 32 と規定されていることから, 本研究でもそれに合わせ, 画像サイズを 32 の倍数とした.



図 1 撮影に使用したドローン




図 2 モデル作成に使用した図 (左: ドローン画像, 右: 取得した画像)

2-3. 抽出モデルの学習

上述の通り、YOLOv5はs, m, l, xという4種類の重みが存在するが、本研究では最も演算負荷の小さいYOLOv5sを使用する。モデルの学習時における損失の推移を図3に示す。この時の損失は以下の式に示すGIoU LOSS関数によって求められた値である。学習開始直後は損失が大きいが、学習が進むにつれ、小さくなり、100~120 epochが経過した時点で値が収束している。これ以上の学習は効果が小さいと判断し、本研究では120 epochまで学習したモデルを使用して検証を行う。

$$GIoU\ Loss = 1 - \left\{ \frac{|A \cap B|}{|A \cup B|} - \frac{|C \setminus (A \cup B)|}{|C|} \right\} \quad (1)$$

3. ドローン画像とAIを組み合わせた車両抽出結果

学習したモデルを用いて車両を抽出した結果を図4, 5に示す。抽出結果を確認するために使用した画像は、モデル作成時に使用しなかったドローン画像と五剣山（香川県高松市、標高375m）調査の際に撮影したドローン画像である。両画像とも災害時の画像ではないものの、前者は抽出モデルの精度評価のため、後者は想定する災害時の道路状況（道路幅、周辺環境など）に近いことから採用した。抽出された箇所はバウンディングボックスと同様の色で囲み、その付近に抽出結果の信頼度を示す。図4, 5より、学習用画像データに写る同程度の大きさの車両は概ね抽出されていることが分かる。一方、図4に関しては、画像奥に位置する車両に関しては抽出されておらず、図5に関しては、左側の車両が重複して抽出されている。これは、モデルの学習に使用した画像枚数が不十分であることや車両そのものが色・車種の組み合わせが非常に多いことが原因として考えられる。そのため、精度向上の観点から学習画像枚数を増やし、より多くの色・車種の車両を学習させる必要がある。しかし、抽出精度を考慮しなければ、“車両”という物体自体は抽出が可能となっており、学習させていない道路上の車両についても抽出、すなわち災害時における道路の閉鎖状況の把握は可能と考える。




図3 損失の推移



図4 車両抽出結果（駐車場）



図5 車両抽出結果（五剣山 道路）

4. まとめ

本研究では、ドローン画像とAIを組み合わせたモデルにより災害時の車両抽出を行った。その結果、学習用画像データに写る同程度の大きさの車両は概ね抽出可能であることが判明した。一方で、画像奥に位置する小さな車両は抽出が困難であった。このことから、抽出対象が学習した対象と同程度の大きさで写っている場合は抽出可能であることが判明した。今後の課題として、現時点では抽出精度などは必ずしも高くないため、学習用画像データ枚数を増やし、より多くの色・車種の車両を学習させ、モデルの改良を行う必要がある。

参考文献

- 1) 久保菜, 全邦釘, 伊藤克雄: YOLOv5を用いた導水路トンネルにおけるチョーキング箇所の検出, AI・データサイエンス論文集, 2巻, J2号, pp.87-96, 2021