

Mask-RCNN を用いた橋梁の腐食損傷インスタンスセグメンテーション

埼玉大学 学生会員 ○劉 佳明
 埼玉大学 正会員 党 紀

1. はじめに

日本では高度経済成長期に多くの橋梁が建設され、2020年時点で橋梁全体の30%が老朽化年限に到達し、十年後の2030年では55%になる。維持管理のため、より高い頻度の定期点検が要求される。また、少子高齢化により、橋梁の保全業務に関わる土木技術者数も年々低下している。一方、近年ではUAVやコンピュータビジョン技術が大きく発展され、より安全、便利な点検技術が可能となっている。

本研究ではUAV点検で得られた画像データから、インスタンスセグメンテーション手法の一つであるMask-RCNNを用いて、橋梁の腐食損傷の自動検出について検討を行う。AIの汎用度を考え、訓練データは点検調書からの腐食写真とし、テストデータはUAV写真とした。その後、アノテーションを行い、データセットを作成した。AIモデルの実用性を評価するため、Lossや精度に関する考察を行った。

2. データセットの準備

本研究で使ったデータは2パターンがある。訓練、検証用のデータは点検調書から抽出した概ね400×400ピクセル程度の低解像度の写真である。テストデータはUAVで撮影した橋梁の4k映像データから4枚の写真を抽出した。検出難易度を考慮し、4Kサイズの写真を144枚の400×400ピクセルの写真に分割し、テストデータに用いた。データは訓練用300枚、検証用20枚、テスト用144枚に配分した(表-1)。今回はオープンソースのVGG Image Annotatorを使い、画像データに対して事前にアノテーションを行った。

表-1 データセットの構成

	訓練データ	検証データ	テストデータ
データ数(枚)	300(点検)	20(点検)	144(UAV)

3. Mask-RCNN の訓練

Mask-RCNNモデルは主に2ステップの画像認識を行う。第1ステップは画像をConvolutional Layerに通し、RPN技術を用い、目標対象を長方形のBounding Boxでマークする。第2ステップはBounding Box内にピクセルレベルで目標検知を行う。最終的に、Bounding Boxと色が塗られた目標対象の写真が得られる。Mask-RCNNではこのような2段階の画像認識を行うことにより、高い正解率の識別写真が獲得できる。

実験データが少ないため、訓練中に転移学習を用いた。今回はCOCOデータセットで訓練済みの重みを導入し、学習率は0.001、Epoch数を50に設定し、Epochごとに100ステップの訓練を行った。

4. 訓練の結果

本研究ではLossと AP_{50} からモデルを評価する。 AP_{50} とは、IoU(Intersection over Union)の閾値を0.5とした場合のAP値である。図-1のように、Epochの変化によるLossの変化を示している。訓練Lossと検証Lossの両方は最初から減少している。その後、訓練Lossはさらに減少するが、検証Lossは一定又は増加していく。

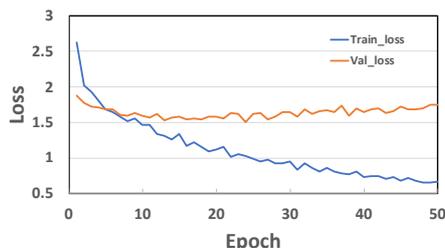
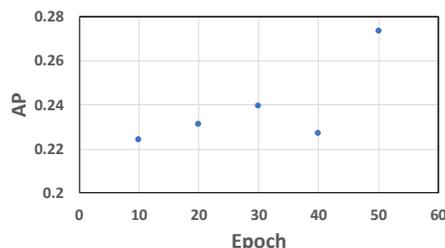


図-1 Epoch-Loss 図

図-2 Epoch- AP_{50} 図

キーワード 橋梁点検, AI, Deep Learning, UAV, Mask-RCNN

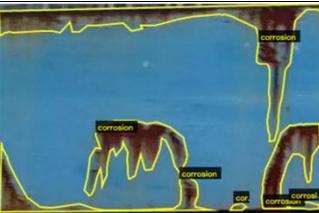
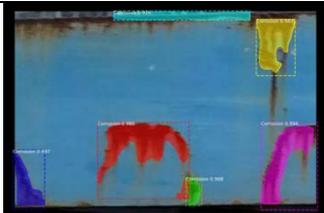
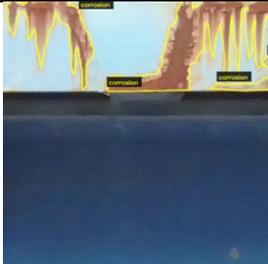
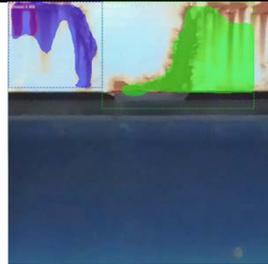
連絡先 〒338-5870 埼玉県さいたま市桜区下大久保255 埼玉大学 工学部 劉佳明 TEL048-858-3005

これは過学習現象と考えられる。 AP_{50} の変化を図-2 に示す。 AP_{50} の計算は多くの時間を要するため、今回は 10 Epoch に一回の頻度で AP_{50} を計算していた。 AP_{50} は Epoch により、はじめに上昇していたが、40Epoch の付近で一旦減少し その後また上昇していた。 5%の差は正常の変動範囲にあるため、モデルの平均的な AP_{50} が 25%付近にあると思われる。 既存の論文によると、COCO データセットで YOLOv3 608×608 は $AP_{50} = 33\%$ であり、Faster RCNN は $AP_{50} = 43\%$ 、Mask-RCNN は $AP_{50} = 72\%$ という良い結果であった。

5. 結果の可視化

以下の写真(表-2)は 50Epoch での重みを使い、計算した。モデルは一定の精度を持っていることがわかった。しかし、(a)の写真のように、上部の細長い腐食が部分認識となっている。(b)は腐食が認識されているが、Bounding Box 内の損傷認識がうまくできていない。原因はサイズの大きな腐食対象に対する認識度が低いということである。(c)の写真は良くない検出例であり、上部の背景が腐食損傷に認識されている。下部の腐食損傷は範囲が広く、細長い部分が認識されていなかった。

表-2 認識写真

	原写真	Ground Truth	Mask-RCNN
(a)			
(b)			
(c)			

6. おわりに

本実験では点検調査の写真を用い、Mask-RCNN の訓練を行った。その後、UAV 写真を用いることで精度のテストを実施した。また、Loss と AP_{50} を指標として、訓練結果の評価とした。

実験の結果では、訓練された AI モデルは多様な腐食損傷に対応できず、サイズの大きな腐食や、細長く写真を跨いだ腐食対象の認識精度が低かった。特に大量の背景(樹木など)が腐食に認識されたことが、 AP_{50} 低下の要因と考える。さらに、実験用のデータ数が少ないため、訓練中では過学習現象があった。今後は Data Augmentation や背景の訓練を加え、モデル精度の改善を行う。

参考文献

1. 日本交通省・道路局：道路メンテナンス年報，2020，p.94
2. He K., Gkioxari G., Dollár P., Girshick R: Mask RCNN, 2017, In: ICCV, p.1, 3
3. L. Liu et al., "Deep learning for generic object detection: A survey," 2018, In: arXiv,1809.02165.