

機械学習を用いた損傷検知システムの基礎的検討

長岡工業高等専門学校

○佐藤 湊太

長岡工業高等専門学校専攻科

学生会員

小林 瑚伯

長岡工業高等専門学校

正会員

井林 康

1. はじめに

国内では多数の橋梁が存在し、現在では5年に一度の目視点検が義務付けられている。また、橋梁点検従事者の不足が深刻化し、点検作業に問題が生じており、近年では画像認識 AI を活用した橋梁点検の効率化が期待されている。先行研究では機械学習と損傷画像を用いて、損傷自動検知システムの構築が行われてきた。しかし、損傷画像に背景が映り込むことで精度が低下するという課題があった。本研究では、背景除去が背景の映りこむ損傷画像の損傷判定に有効であるか評価することを目的とする。

2. セマンティックセグメンテーション

2.1 概要

セマンティックセグメンテーションは、画像内の全画素にラベルやカテゴリーを関連付けるディープラーニングのアルゴリズムである。本研究では背景の映り込む橋梁の損傷画像に用い、背景と構造物の分類及び、腐食の判定を行う。背景と構造物の分類は背景を除去するために行う。

2.2 使用するデータ

本研究ではデータセットに用いる背景の映り込む損傷画像の収集に、国土交通省が構築しているデータプラットフォームの全国道路施設点検データベース (xROAD)¹⁾を用いた。データベースは損傷が確認された橋梁を指定し、画像をダウンロードすることができるため、データセットの作成の効率化を図れる。データセットに用いる画像は全国の橋梁の損傷画像の内、損傷レベルがIIおよびIIIの画像を対象とした。また、損傷の種類は腐食のみを対象とした。

2.3 教師データの作成

データベースから収集した損傷画像は、LabelMe というアノテーションツールでラベル付けを行い、

表-1 背景除去の教師データの構成

Training	Test	Total
200	30	230

表-2 腐食の教師データの構成

Training	Test	Total
270	30	300

Python と画像処理ライブラリである OpenCV を用いてマスク画像を出力する。収集した損傷画像とマスク画像は 128×128 ピクセルにリサイズし、それぞれを入力画像、正解画像として教師データを構成する。

3. 使用するモデルの概要

3.1 背景除去モデル

背景除去モデルの教師データの構成は表-1 に示す。なお、ここで Training データは 9 倍に拡張した。拡張手法には、水平反転、回転、ぼかしを用いた。

モデルの構築にはソニーの Neural Network Console (NNC) を活用し、アーキテクチャは U-Net を採用する。U-Net は、スキップ構造があることで、エンコード層を経るごとに減る元画像の特徴の損失を軽減し、入力画像の詳細な情報を保持しながら画像を再構築できる。そのため、小規模なデータセットでも高いパフォーマンスを発揮することができる²⁾利点があるため採用した。

背景除去モデルで背景を除去するイメージを図-2 に示す。始めに収集した背景が映り込んだ画像データの構造物を判定した推論画像を出力する。その後出力された推論画像の内、背景と判定された領域 (黒の領域) を抽出し、元画像に重ねることで背景を除去した画像データを作成する。

3.2 腐食の判定モデル

腐食の判定には先行研究で構築された腐食の判定



図-2 背景を除去するイメージ



図-3 腐食の判定のイメージ

モデルを使用した。腐食の判定モデルの教師データの構成は表-2に示す。なお、ここで教師データは9倍に拡張した。構築は背景除去モデルと同様にエンコーダ層が7層のU-Netを使用した。このモデルのIoUは腐食に対し、85.0%である。腐食の判定のイメージを図-3に示す。

4. 評価指標と評価結果

4.1 評価指標

本研究では、構造物の判定の評価指標に対象領域全体の一致度を評価するために適したIoUを採用した。腐食の判定モデルの評価指標には不均衡データに強く、見逃しや誤検出のバランスを評価できるFscoreを採用した。FscoreはRecall(再現率), Precision(精度)の調和平均である。TP(正例を正しく予測した数), FP(負例を正例と誤って予測した数), FN(正例を負例と誤って予測した数)を用いるとIoUとFscoreは次式で計算される。

$$IoU = \frac{TP}{TP + FP + FN} \quad Recall = \frac{TP}{TP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Fscore = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

4.2 評価結果

表-3 Fscoreの比較

	元画像	背景除去した画像
Fscore	67.5%	69.5%

背景除去モデルの平均IoUは60.0%という結果となった。平均IoUは低い結果だったが、それぞれのデータのIoUを比較すると、IoUが75%を上回るデータの背景は空や草など色が明るい特徴があり、75%を下回る背景は影や川、土など色が暗い特徴が見受けられた。色の暗い背景を構造物と誤判定するケースが多かった。原因としては存在する構造物の色が比較的暗いものが多いためと考えられる。

背景除去した画像と除去していない画像の損傷判定のFscoreを比較した結果を表-3に示す。平均Fscoreを比較すると背景除去した画像は背景除去していない画像と比べると、2%向上していた。この結果から、わずかながら背景を除去することで損傷判定の精度は向上したと考えられる。

5. まとめと今後の展望

本研究では、先行研究における損傷画像に背景が映り込むことで精度が低下する課題に対し、背景除去が有効であるかを評価した。その結果Fscoreによる評価でわずかながら背景除去の有用性が示唆された。しかし、影や川、土など暗い色の背景では誤判定が多いという課題が残っており、今後は多様な背景パターンを含む教師データを活用することでさらなる判定精度の向上が期待されると考える。また、本研究では機械学習を用いたことで背景除去の自動化に成功した。今後、背景除去の自動化は損傷検知システムの向上だけでなく、橋梁部材の判定など他の分野に対しても応用できると考える。

参考文献

- 1) 国土交通省道路局：道路橋定期点検要領 平成31年2月
https://www.mlit.go.jp/road/sisaku/yobohozen/tenken/yob_o4_1.pdf
- 2) 全国道路施設点検データベース (xROAD)
<https://road-structures-db.mlit.go.jp>