

Deep Learning を用いた鋼製支承の自動損傷判定の検証

大日本コンサルタント 正会員 ○龍田 斉 大日本コンサルタント 正会員 平山 博
 東京大学 正会員 長井 宏平 大日本コンサルタント フェロー 横山 広
 日本システムウェア 非会員 野村 貴律 大日本コンサルタント 非会員 宮川 輝幸

1. 目的

近年、Deep Learning による画像認識の精度向上が著しい。本研究では、少子高齢化に伴い技術者が不足している道路橋の維持管理の効率化を目的として、Deep Learning を用いた画像認識による橋梁部材の損傷自動判定の可能性を検証した。検証は、道路橋を構成する部材において小規模で特徴的な形状を有するため、点検調書の様式の差異により写真の内容に差が生じにくい鋼製支承(線支承(写真-1)、BP 支承(写真-2))を対象に実施した。対象とする損傷種類は、鋼製支承が有する損傷のうち、最も多く発生する「防食機能の劣化」とした。また、損傷画像から損傷部材のみを切り出した画像を用いて学習した際の判定精度の向上についても検証した。



写真-1 線支承



写真-2 BP 支承

2. 概要

検証は主に①学習用データの作成と、②機械学習、③学習精度の検証の3つに大別され、図-1 のフローに沿って実施した。各工程の作業内容を以下に示す。

2. 1. 学習用データ作成

Deep Learning 用の学習データは、新潟県下市町村が新潟県橋梁点検要領¹⁾に準拠して約 10 年間実施した点検結果から、鋼製支承の損傷画像を抽出し、以下手順で作成した。

(1) 損傷画像選別

国土交通省が工事写真の画質について規定したデジタル写真管理基準²⁾は、平成 28 年 3 月の改訂まで、工事写真の解像度を約 100 万画素程度と規定していた。各自治体が策定している点検要領に写真の解像度に関する規定が無い場合、これに準ずる傾向がある。また、損傷個所の明確化を目的として、画像中の損傷個所周辺に円や矩形、矢印等のマーキングを追加した損傷画像なども混在している。これらの画像は、元画像に比べ、解像度が劣化し、損傷程度が目視で把握しにくい。Deep Learning の精度向上の観点から、このような画像は除外した。

(2) 損傷画像再判定

データ蓄積中に新潟県橋梁点検要領が複数回改定されている。したがって、点検結果に異なるレギュレーションによる損傷判定区分が混在している可能性がある。これに対し、統一的な尺度のデータセットによる学習とするため、損傷画像に対し再判定を実施した。

(3) 損傷個所の切り出し

損傷画像から損傷個所以外を除外した場合の学習精度の向上を検証するため、損傷個所のみを切り出した画像を別途用意した。

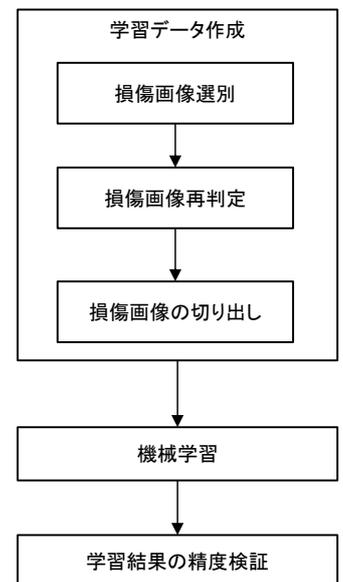


図-1 検証フロー

キーワード 橋梁点検、鋼製支承、画像処理、Deep Learning

連絡先 〒330-6011 さいたま市中央区新都心 11-2 大日本コンサルタント株式会社 TEL048-615-2229

2. 2. 機械学習

(1) 採用モデル

本研究において、損傷画像の学習用に採用した Deep Learning のモデルは、CNN (Convolutional Neural Network) である。CNN は、写真画像から車両や文字を識別するなど、画像内の物体検知において高い精度が証明されている。上記モデルに損傷画像と該当する損傷程度の判定区分(表-1)をセットにして入力し、各判定区分に対応した損傷画像の特徴量を学習させた。

(2) グループ分け

学習と学習結果の評価を、同じデータで実施すると、学習結果の汎用性が評価できない。このため、学習用と評価用の画像セットを分離した。具体的には、市町のデータを6グループに分割し、5グループで学習、1グループで評価を実施した。これを全グループ分の計6ケース評価した。

3. 学習結果の精度検証

CNN による学習結果と判定結果を表-2 に示す。

表から、学習画像に対する精度はいずれも 88%以上と高いものの、判定用画像については、50%を切るケースから 88%近い精度を有するケースまで、大きなばらつきが生じている。また、損傷箇所切り出しの効果については、ケース1及びケース4を除けば、10~13%程度向上していることが確認できる。判定用画像に対する精度がばらつく原因として考えられるのは、学習用画像が特定の区分に偏りが生じていることである。例として表-3 にケース2の各評価区分における正解と予測の損傷画像枚数を示す。表から損傷画像が区分 e に偏っていることが確認できる。また、区分 a (損傷なし) が1枚も存在しないことも影響している可能性がある。これは点検要領に損傷箇所のみを記録に残す規定に起因する。これを解消するため、機械学習用の未損傷の鋼製支承画像を作成し、追加する予定である。

4. まとめ

本研究では、Deep Learning を用いた鋼製支承の損傷自動判定の可能性を検証した。得られた知見を以下に示す。

- (1) Deep Learning の学習用に、損傷画像を用いる場合は、低解像度のもの等、学習に適していないものをフィルタリングする必要がある。
- (2) 損傷画像から損傷箇所を切り出して学習させることにより、Deep Learning の判定精度が向上する。
- (3) 学習する各グループの枚数に偏りがあると、判定精度にばらつきが生じる。
- (4) 区分 a (損傷なし) の画像については、点検結果とは別に入手する必要がある。

なお、本研究で用いたデータは新潟県建設技術センターを通し、新潟県市町村から提供されたものです。ここに謝意を表します。

参考文献

- 1)新潟県土木部道路管理課, 「新潟県定期点検要領[標準点検編]」(2014).
- 2)国土交通省, 「デジタル写真管理基準」(2008).

表-1 損傷程度の評価区分(防食機能の劣化)

区分	一般的状況
a	損傷なし
b	-
c	最外層の防食塗膜に変色が生じたり、局所的なうきが生じている。
d	部分的に防食塗膜が剥離し、下塗りが露出している。
e	防食塗膜の劣化範囲が広く、点錆が発生している。

表-2 学習結果と判定

画像種別	オリジナル						切り出し画像					
	1	2	3	4	5	6	1	2	3	4	5	6
ケース番号												
画像枚数(学習用)	917	919	916	924	922	917	917	919	916	924	922	917
画像枚数(判定用)	186	184	187	179	181	186	186	184	187	179	181	186
正解率(学習用)	90.4%	88.1%	88.3%	88.6%	88.4%	89.2%	100.0%	92.6%	88.8%	90.9%	92.8%	92.4%
正解率(判定用)	48.8%	69.6%	75.1%	69.7%	73.6%	57.7%	48.7%	80.4%	87.9%	70.7%	77.7%	71.1%

表-3 ケース2における各評価区分の損傷画像枚数

ケース2		正解評価区分		
		区分c	区分d	区分e
予測評価区分	区分c	17	17	16
	区分d	84	101	82
	区分e	50	185	1496