

## (34) 鋼製支承の自動損傷判定に関する Deep Learning の有効性検証

龍田 齊<sup>1</sup>・長井 宏平<sup>2</sup>・野村 貴律<sup>3</sup>  
平山 博<sup>4</sup>・横山 広<sup>5</sup>・宮川 輝幸<sup>6</sup>

<sup>1</sup>正会員 大日本コンサルタント(株) インフラ技術研究所 事業開発部 ICTソリューション室  
(〒330-6011 埼玉県さいたま市中央区新都心 11-2L.A.タワー)

E-mail:tatsuta@ne-con.co.jp

<sup>2</sup>正会員 東京大学准教授 生産技術研究所 (〒153-8505 東京都目黒区駒場 4-6-1)

E-mail:nagai325@iis.u-tokyo.ac.jp

<sup>3</sup>非会員 日本システムウエア(株) プロダクトソリューション事業本部デバイスソリューション事業部  
(〒150-0036 東京都渋谷区南平台町 2-15)

E-mail:tnomural@gw.nsw.co.jp

<sup>4</sup>正会員 大日本コンサルタント(株) インフラ技術研究所  
(〒330-6011 埼玉県さいたま市中央区新都心 11-2L.A.タワー)

E-mail:hirayama@ne-con.co.jp

<sup>5</sup>フェロー 大日本コンサルタント(株) インフラ技術研究所 調査研究部 保全エンジニアリング研究室  
(〒330-6011 埼玉県さいたま市中央区新都心 11-2L.A.タワー)

E-mail:yokoyama\_hiroshi@ne-con.co.jp

<sup>6</sup>非会員 大日本コンサルタント(株) 技術統括部 (〒170-0003 東京都豊島区駒込 3-23-1)

E-mail:miyakawa@ne-con.co.jp

我が国の多数の橋梁は既に架設から半世紀が経過し、その維持管理の重要性が高まっている。加えて、少子高齢化に伴う技術者減少の加速が懸念されている。本研究では、道路橋の維持管理の効率化を目的として、画像認識で高い精度を有する Deep Learning を活用した橋梁部材の損傷自動判定の可能性を検証した。検証対象の橋梁部材は、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を対象とした。

また、Deep Learning を用いた生成モデルの 1 種である GAN(Generative Adversarial Networks)を用いて Deep Learning の学習画像として利用できる疑似損傷画像の生成を試みた。

**Key Words:** deep learning, steel bearing, coating deterioration, automatic judgement

### 1. はじめに

近年、Deep Learning による画像認識の精度向上が著しい<sup>1)</sup>。本研究では、少子高齢化に伴い更なる技術者不足が懸念され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(線支承および BP 支承(図-1))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。検証では、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確認した。



a)線支承

b)BP 支承

図-1 鋼製支承

また、損傷判定区分ごとの画像数の偏りを補うために、GAN(Generative Adversarial Networks)を用いて疑似損傷画像の生成を試みた。GANとはDeep Learningを用いた生成モデルの一種で、学習画像から疑似画像を生成することができる<sup>2)</sup>。本研究では、損傷の自動判定と同様に、鋼製支承を対象として、Deep Learningの学習に有用な疑似損傷画像をGANによって生成できるか検証を実施した。

## 2. 概要

検証は①自動損傷判定の検証と、②疑似損傷画像の生成の2つに大別され、図-2に示すフローに沿って実施した。以下に各手順の内容を示す。

## 3. 自動損傷判定の検証

### (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<sup>3)</sup>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、以下の手順で作成した。

#### a) 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<sup>4)</sup>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。

#### b) 損傷画像再判定

新潟県橋梁点検要領は平成19年度の策定から現在までの間に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。

#### c) 損傷個所の切り出し

鋼製支承の損傷画像には、支承の周辺に、沓座、軀体、主桁、対傾構等、様々な部材が写りこんでいる。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。

## (2) 機械学習

### a) 採用モデル

本研究で損傷画像の学習用に採用したDeep Learningのモデルは、CNN(Convolutional Neural Networks)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。

### b) 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。

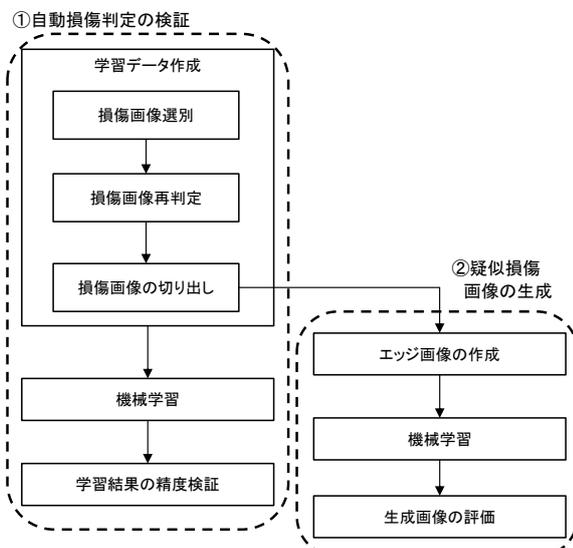


図-2 実施フロー

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)	<b>48.8%</b>	<b>69.6%</b>	<b>75.1%</b>	<b>69.7%</b>	<b>73.6%</b>	<b>57.7%</b>	<b>48.7%</b>	<b>80.4%</b>	<b>87.9%</b>	<b>70.7%</b>	<b>77.7%</b>	<b>71.1%</b>

(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、判定用画像に対しては、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。

表-3 ケースにおける各評価区分の画像枚数

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

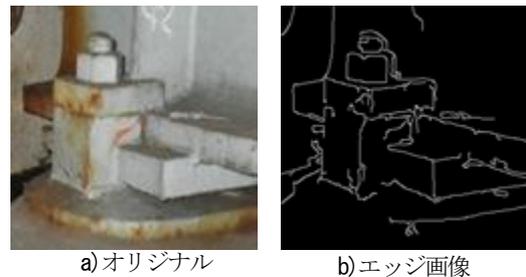


図-3 鋼製支承のエッジ画像

4. 疑似損傷画像の生成

(1) エッジ画像の作成

GAN の学習は鋼製支承の画像に加え、特徴画像（鋼製支承の特徴部分のみを残した画像）が必要となる。本研究において、特徴画像は支承画像からエッジのみを抽出した画像（図-3）とした。エッジとは画像中の輝度が急激に変化する箇所を指し、エッジ画像は物体の輪郭だけ抽出したような画像になる。エッジ画像の作成は、3.(1)c)で作成した支承部分のみを切り出した画像から、画像処理を用いて、支承の輪郭部のみを抽出することで生成した。

(2) 機械学習

GAN への学習データは、支承画像と合わせて支承の特徴画像であるエッジ画像をペアで用意し、入力する。

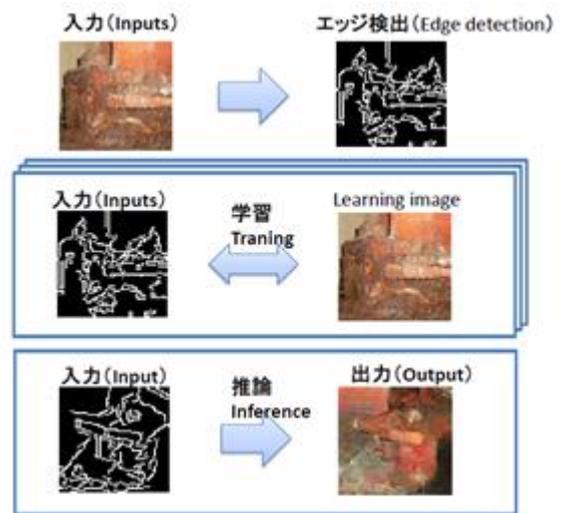


図-4 GANの学習・生成イメージ

学習用に使用した鋼製支承の画像枚数は 972 枚である。学習を終えたモデルは、任意の支承のエッジ画像を入力すると、学習結果を基にした疑似損傷画像を生成する。図-4 に GAN の学習および画像出力イメージを示す。

### (3) 生成画像の精度確認

学習を終えた GAN によって生成した支承損傷画像の一部を図-5 および図-6 に示す。生成に用いた画像は、学習と重複していない 197 枚を使用した。図中の画像は、上段がオリジナル、中段がエッジ画像、下段が GAN が生成した支承画像である。図より、学習データの画像と類似しつつも、印象の異なる支承画像を生成していることが確認できる。本画像を CNN に投入することにより、支承の画像判定の精度の向上が期待できる。

## 5. 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。

- 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。
- 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。
- 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。
- 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。
- 鋼製支承画像及び鋼製支承のエッジ画像を GAN に学習させることにより、CNN の学習に活用が期待できる疑似損傷画像を作成することができた。今後は、CNN にこれらの画像を入力し、学習精度が改善するか検証する予定である。

**謝辞：**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) Krizhevsky A., Sutskever I. and Hinton G. E. : ImageNet classification with deep convolutional neural networks, *NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems*, Vol.1, pp. 1097-1105, 2012.
- 2) Phillip I., Jun-Yan Z., Tinghui Z. and Alexei A. E. : Image-to-Image Translation with Conditional Adversarial Networks, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 5967-5976, 2017.
- 3) 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.
- 4) 国土交通省：デジタル写真管理基準，2008.



図-5 GAN 学習画像と生成画像例 1 (上段：オリジナル，中段：エッジ画像，下段：生成画像)

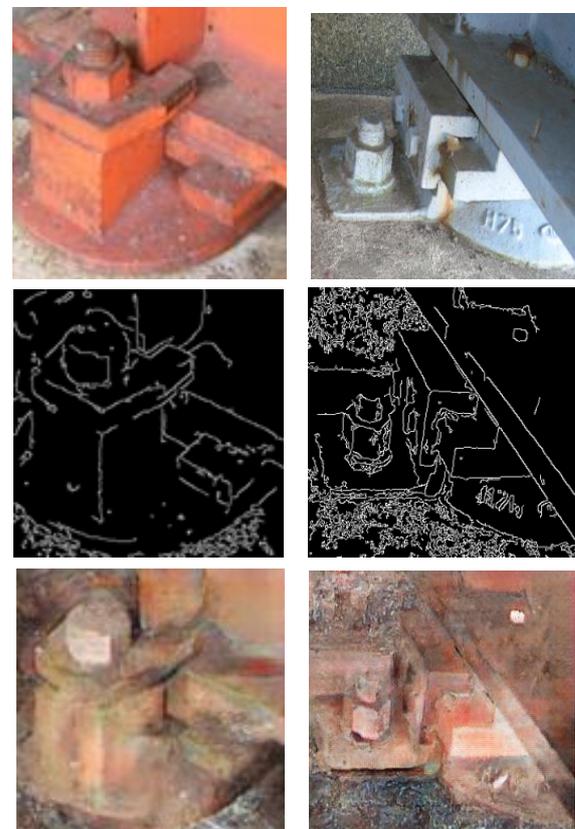


図-6 GAN 学習画像と生成画像例 2