

橋梁管理カルテと AI 技術を用いた損傷原因および補修工法推定の可能性検証

大日本コンサルタント正会員 ○龍田 斉
産業技術総合研究所 非会員 永見 武司
金沢大学 正会員 近田 康夫

大日本コンサルタント フェロー 横山 広
金沢大学 フェロー 梶谷 浩
国土交通省金沢河川国道事務所 非会員 山下 忠男

1. 背景と目的

平成 26 年度の道路法改正により、国内の橋梁は 5 年ごとに定期点検が義務付けられ、その点検結果に基づいた損傷対応として補修・補強が実施されている。しかし、地方自治体の多くは橋梁維持管理に必要な専門知識を有する技術者が確保できていない。加えて、少子高齢化により橋梁維持管理に従事する労働力が減少傾向にあることから、ICT 技術の活用による生産性向上が求められている。

一方、画像からの物体検出等で AI 技術の 1 種である Deep Learning を用いた手法の精度向上が近年顕著である。本研究では、地方自治体に所属する道路管理者の補修工法選定の意思決定補助を目的として、橋梁管理システムによって記録された橋梁管理カルテ情報から損傷原因および補修工法の推定に AI 技術が活用できるか検証した。

2. 概要

検証は①学習用データ作成と、②機械学習及び③学習結果の精度検証の 3 ステップに大別され、図-1 に示すフローに沿って実施した。以下に各ステップの内容を示す。

3. 学習用データ作成

Deep Learning 用の学習データは、国土交通省金沢河川国道事務所が管理する 453 橋の 10 年分の橋梁管理カルテデータを用いた。橋梁管理カルテデータには橋梁の緒元の他に、損傷原因、補修工法が記載されている¹⁾。表-1 に橋梁管理カルテデータの主なデータ項目を示す。これらの橋梁管理カルテデータを、Deep Learning を適用するために、以下手順で加工した。

3.1. one-hot 表現への変換

等級や設計活荷重等、システムが表示するコードを選択する入力項目についてはコードの大小が他項目へ与える影響を排除することを目的として、one-hot 表現への変換を実施した。具体的には、各コードについてコード種類分列を用意し、当該データが項目に該当する場合は 1 に、それ以外は 0 にする。図-2 に one-hot な表現変換イメージを示す。

3.2. 正規化

橋長や橋面積、幅員等、数値を入力する項目については、値の大小の影響を排除することを目的として、0.0 から 1.0 の間で正規化した。正規化後の値 v' は正規化前の値 v 及び正規化対象の項目の最大値 v_{max} および最小値 v_{min} より以下式を用いて算出した。

$$v' = \frac{v - v_{min}}{v_{max} - v_{min}} \quad (1)$$




図-1 検証フロー

表-1 橋梁管理カルテのデータ項目

諸元	点検	補修
橋種、交通量、橋長、橋面積、構造形式、防水工有無、等級、設計活荷重、設計震度、平面形状、平面線形、縦断勾配、迂回路有無、交差物名称、塩害地域区分、幅員構成、添架物、塗装仕様、点検施設、排水施設	損傷部材、材料、損傷種類、対策区分、損傷原因(確定)、損傷原因(推定)	工法

元データ		one-hot表現			
橋梁名	橋種	橋梁名	橋種		
A橋	鋼	A橋	鋼	RC	PC
B橋	RC	B橋	0	1	0
C橋	PC	C橋	0	0	1

図-2 one-hot 表現への変換

706項目

橋梁名	橋長	交通量	橋種			平面形状			迂回路
			鋼	RC	PC	直橋	斜橋	曲線橋	
A橋	0.32	0.57	1	0	0	0	1	0	0
B橋	0.21	0.13	0	1	0	1	0	0	0
C橋	0.38	0.22	0	0	1	1	0	0	0

図-3 データ統合のイメージ

3.3. データ統合

変換データを結合し、Deep Learning への入力データとした。結合後のデータは709項目、160,724レコードとなった。結合後のデータのイメージを図-3に示す。

4. 機械学習

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)²⁾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。本研究で用いたCNNのモデルを図-4に示す。上記モデルに結合データと該当する損傷種類、対策区分、原因、補修工法をセットにして入力し、学習させた。

5. 学習結果の精度検証

CNNの学習結果を表-2に示す。表から、いずれの項目も推定値が実用精度を有していない。これは、学習データの項目数の多さと、データの絶対量が少ないことが影響していると推察される。これらを解消するため、データ数を増やすとともに、主成分分析とクラスター分析を活用し、データ項目数を削減し、精度向上を図る予定である。




図-4 CNNのモデル

7. まとめ

本研究では、Deep Learning を活用した橋梁点検カルテデータから損傷原因と補修工法の推定について可能性を検証した。得られた知見を以下に示す。

- (1)橋梁管理カルテのデータを Deep Learning のモデルへ投入するには、one-hot 表現への変換や正規化等の加工処理が必要である。
- (2)橋梁管理カルテデータを CNN へ適用する際は、一つの国道事務所のデータでは推定精度を得ることはできない。精度向上にはデータ量の増強と、主成分分析やクラスター分析等による項目数の削減が有効と推測される。

表-2 学習結果

推定項目	判定精度
対策区分	62%
損傷種類	54%
損傷原因(確定)	55%
工法	56%

謝辞:本稿は北陸・道路メンテナンス会議に設置された「道路橋の維持管理における各構成部材の限界状態ならびに AI 技術の活用に関する検討ワーキンググループ」の研究成果をまとめたものである。ここに関係された皆様に謝意を表します。

参考文献

- 1) 国土交通省道路局：橋梁の維持管理の体系と橋梁管理カルテ作成要領（案）,2004.
- 2) 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.