

人工知能を用いた鋼橋における腐食箇所を検出に関する検討

日本大学 正会員 ○中村 和樹
日本大学 正会員 子田 康弘

1. はじめに

高度経済成長期に集中的に整備された道路橋の一斉老朽化に対し効率的な点検や診断が行える技術の開発が急務となっている。現在、建設後 50 年を超えた 2 m 以上の橋梁の割合は全体の 2 割程度であるが、10 年後には 4 割、20 年後には 7 割に達する¹⁾。また、人口の減少や少子高齢化による技術者の減少が懸念されており、効率的かつ低予算による橋梁の点検や診断といった維持管理が求められている。本研究では、近年土木分野においてもその利用に注目が集まる人工知能の 1 つであるディープラーニングを適用し、鋼橋における腐食箇所の検出について点検写真を用いて検討した。

2. 検討対象と使用データ

福島県内の鋼橋を研究対象として、平成 28 年度に福島県が実施した道路橋点検結果²⁾における、いわき市（以下、いわき地区）および県南部（以下、県南地区）周辺の鋼橋について、状況写真からそれぞれ 31 枚、48 枚を元画像として抽出して学習モデルの構築に使用した。元画像は人工知能で学習および評価するためのトレーニングデータ兼テストデータとするために、128×128 ピクセルとなるグリッドを設定した。各グリッドにおいて、腐食、塗膜変状、健全、判定対象外（鋼部材以外）の 4 種類にラベリングし、いわき地区ではそれぞれ 594、196、20、1782 の計 2592 グリッド、県南地区ではそれぞれ 1234、466、121、2468 の計 4289 グリッドを、後述するネットワークアーキテクチャの入力層データとした。

3. 学習モデルの構築

画像を対象とした検出や分類での問題は、入力となる画像から (1) 特徴を抽出、(2) 抽出した特徴を次の抽出は人間が自ら設計する一方で、ディープラーニングでは特徴を含めて学習することにより、特徴として抽出する可否の判断が難しい場合でも、特徴量を獲得する可能性が期待される。したがって、本研究では、腐食検出にディープラーニングの 1 つである畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) を使用した。

腐食検出への CNN の導入は、オープンソースのフレームワークである Caffe³⁾を利用した。ネットワークアーキテクチャには AlexNet⁴⁾を用いて、腐食検出のための学習モデルを構築した。AlexNet は 2012 年の画像認識コンテスト ILSVRC において優勝した CNN であり、入力層、5 つの畳み込み層と 3 つのプーリング層、3 つの全結合層の全 12 層からなる多層ニューラルネットワークのアーキテクチャである。この構築に係り、初期の学習率 (Learning rate) は 0.01、全調査回数 (Epoch) は試行錯誤的に決定した。入力層については、各グリッドのデータサイズをオーバーサンプリングして 256×256 ピクセルへ変換して使用した。出力層については、入力層と同様に 4 種類に分類される設定とした。



(a) 元画像 (b) 分類結果

■ 腐食 ■ 塗膜変状 ■ 健全 ■ 判定対象外

図 1 腐食箇所の検出例

キーワード 鋼橋, 腐食, ディープラーニング, 機械学習, AlexNet

連絡先 〒963-8642 福島県郡山市田村町徳定字中河原 1 日本大学工学部情報工学科 TEL 024-956-8831

4. 解析結果

各ラベルにおける分類正解率の算出に係り、判別効率表を作成することにより腐食箇所の検出結果を評価した。判別効率表は、分類されるべきラベルを列に、分類されたラベルを行にとった正方行列である。この行列の対角成分は、各ラベルにおける正分類の分類正解率を示し、他の要素は誤分類であることを示す。

はじめに、本研究で構築した学習モデルの妥当性を評価するため、学習モデルの構築に用いたトレーニングデータをテストデータとして入力することにより分類正解率を算出した。その結果、全ラベルの平均分類正解率（総合精度）は各地区の元画像による学習モデルおよび両地区を統合した元画像による学習モデルの3モデルから、それぞれ99%、99%、97%であり、学習モデルとして妥当であることが分かった。図1に腐食箇所の検出例を可視化した結果を示す。

つぎに、構築した学習モデルに他の地区のトレーニングデータをテストデータとして入力することにより、未知のデータへの有効性を評価した。いわき地区の元画像による学習モデルに県南地区の元画像をテストデータとして入力した結果、腐食の分類正解率は59%であった。県南地区の元画像による学習モデルにいわき地区の元画像をテストデータとして入力した結果、腐食の分類正解率は54%であった。さらに、猪苗代町にある拡幅橋の現地調査を実施し、取得した状況写真4枚をテストデータとして入力した。この結果、腐食の分類正解率は、いわき地区（表1）、県南地区（表2）、両地区（表3）の元画像による学習モデルから、それぞれ67%、78%、80%であり、総合精度はそれぞれ54%、77%、81%であった。この結果から、トレーニングデータ数の増加に伴い分類正解率が向上すると考えられる。

5. まとめ

人工知能を適用した鋼橋の腐食検出の結果から、AlexNetを用いた腐食の分類正解率を評価した。これにより、鋼橋全体における腐食の面積推定の可能性が示された。今後は、トレーニングデータを充実させるため、より多くの道路橋点検結果を学習モデルの構築に用いることにより、腐食検出の精度向上を図る。

謝辞 本研究は株式会社小野工業所の高橋明彦氏と株式会社郡山測量設計社の神永秀明氏にご協力頂いた。また、日本大学大学院工学研究科の佐藤直人氏には解析の支援を頂いた。本研究で使用した道路橋点検結果は、福島県より提供して頂いた。ここに記して、関係者に謝意を表す。

参考文献

- 1) 国土交通省, 道路構造物の現状(橋梁), http://www.mlit.go.jp/road/sisaku/yobohozen/yobo1_1.pdf
- 2) 福島県, 平成28年度 橋梁点検結果(福島県管理道路), https://www.pref.fukushima.lg.jp/uploaded/ldata/336999_818671_misc.pdf
- 3) Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, T. Darrell: Caffe: Convolutional Architecture for Fast Feature Embedding, arXiv preprint arXiv:1408.5093, 2014.
- 4) A. Krizhevsky, I. Sutskever and G.E. Hinton: Proc. Advances in Neural Information Processing Systems 25, NIPS foundation, pp.1090, 2012.

表1 いわき地区モデルによる分類結果

判定	腐食	塗膜変状	健全	判定対象外
腐食	67%	8%		13%
塗膜劣化	3%	13%		0%
健全	2%	6%		0%
判定対象外	28%	73%		88%

表2 県南地区モデルによる分類結果

	腐食	塗膜変状	健全	判定対象外
腐食	78%	17%		15%
塗膜劣化	8%	69%		2%
健全	0%	3%		0%
判定対象外	14%	11%		83%

表3 いわき・県南地区モデルによる分類結果

判定	腐食	塗膜変状	健全	判定対象外
腐食	80%	24%		12%
塗膜劣化	6%	56%		1%
健全	0%	1%		0%
判定対象外	14%	19%		88%