

ディープラーニングを用いた福島県 北部における鋼橋の腐食検出

平子育優[†] 中村和樹^{††} 和泉勇治^{††} 子田康弘^{††}

本研究は、平成 28 年度に福島県が実施した道路橋の点検結果から、福島県北部（県北地区と会津地区）における鋼橋の状況写真を用いて学習モデルの構築を行った。この学習モデルに、猪苗代地区における現地調査により取得した状況写真をテストデータとする評価を行った結果、腐食の分類正解率は 88%であった。本研究における学習モデルは、既往の腐食の分類正解率と比較して高い腐食検出精度を持つことが分かった。

Corrosion detection for steel girder bridges in Northern part of Fukushima using a deep learning

Yasuhiro Hirako Kazuki Nakamura Yuji Waizumi and
Yasuhiro Koda

This paper shows the feasibility of detecting for the corrosion of steel girder bridges applied to a deep learning using the photo imagery with legal checking routine. The detection model was developed by using the images acquired the regions of kenhoku and Aizu in Fukushima prefecture which was validated to be applied the ground truth data obtained from the other region of Inawashiro. The accuracy of the corrosion detection in this study was 88% which was higher than those of previous results.

1. はじめに

道路や橋、鉄道等の日本の社会インフラは、高度経済成長期に集中的に整備され日本の発展に大きく貢献した。その一方で、整備されたインフラは急速な老朽化が懸念されている。建設後 50 年を超えた 2 m 以上の橋梁の割合は、橋梁全体の 2 割程度であるが、10 年後には 4 割、20 年後には 7 割に達すると予測されている¹⁾。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、橋梁の効率的な維持と管理が求められている。

近年、ディープラーニングを用いた鋼橋の腐食検出に関する研究が実施されており^{2) ~4)}、さらなるトレーニングデータの拡充と学習モデルの評価が課題となっている。本研究では、福島県の北部（県北地区および会津地区）における鋼橋を対象に、ディープラーニングを用いた腐食検出の可能性を調べた。

2. 研究対象・使用データ

本研究では、福島県の北部に位置する県北地区および会津地区における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から、県北地区、会津地区の状況写真から ENVI を用いてそれぞれ 93, 71 (計 164) 元画像を学習モデル構築のためのトレーニングデータとした。学習モデル構築に使用するトレーニングデータは、元画像から 128×128 ピクセルを小領域とするブロックに分割し、これら各ブロック画像に対して、腐食、塗膜変状（塗膜色の色褪せなど）、健全（塗膜色に経年変化が見られない）、判定対象外（コンクリート部材などの鋼材部以外）の 4 種類としてラベリングを行い、ブロック画像内に複数のラベルが混在する場合は、前述の順番を優先順位として最も優先順位の高いラベルを付与した。ブロック数は県北地区において腐食、塗膜変状、健全、判定対象外がそれぞれ 7904, 6093, 99, 7936 (計 22032)、会津地区においてそれぞれ 6549, 3079, 40, 5632 (計 15300) となった。図 1 にラベリングされたブロック画像の例を示す。構築した学習モデルは、現地調査により得られた猪苗代地区の状況写真（図 2）を元画像としたテストデータを使用して学習モデルの評価を行った。

3. 学習モデル構築

本研究で構築する学習モデルは、ディープラーニングのネットワークの構造に AlexNet⁵⁾ を用いて、出力層は入力層と同様に 4 と設定した各ブロックは AlexNet の入

[†] 日本大学大学院工学研究科
Graduate School of Engineering, Nihon University

^{††} 日本大学工学部
College of Engineering, Nihon University

カデータサイズに合わせるため、256×256 ピクセルへオーバーサンプリングして使用した。初期の学習率を 0.01、全調査回数（以下、Epoch と呼ぶ）の決定は、100 から 300 の間を 25 ステップで可変させて学習し、過学習にならない Epoch を調べた。具体的には、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する自己評価により、Epoch の増加に伴う分類正解率の向上を調べ、正解率の向上が鈍化した




図1 ブロック画像のラベリングの一例

時の値を学習モデルにおける仮の Epoch とし、仮の Epoch は 225 と求められた。その後、仮決定した Epoch を起点として、Epoch を 1 ステップで可変させながら ±10 ステップまで自己評価による分類正解率を調べることににより、最終的な学習モデルの Epoch を決定した。その結果、学習モデルにおける Epoch は 233 に決定した。

表1 北部モデルの自己評価の結果

判定	腐食	塗膜変状	健全	判定対象外
腐食	99.3%	1.3%	0%	0.1%
塗膜変状	0.4%	98.6%	0.7%	0%
健全	0%	0.1%	99.3%	0%
判定対象外	0.3%	0%	0%	99.9%

表2 猪苗代地区をテストデータとした北部モデルの評価結果

判定	腐食	塗膜変状	健全	判定対象外
腐食	88.8%	11.0%	0%	7.3%
塗膜変状	7.6%	80.6%	0%	0%
健全	0.3%	5.6%	92.7%	0%
判定対象外	3.3%	2.8%	0%	92.7%

4. 解析結果

3 章で構築した学習モデルに、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し、自己評価を行った結果を表 1 に示す。この表は判別効率表として示しており、テストデータが分類されるべきラベルを列に、テストデータが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いて正しく分類された正解率を示し、他の要素は誤分類の割合を示す。この表から、各クラスの分類正解率は 98%~99%（総合精度 99%）であった。

学習モデルの汎化性能を評価するため、図 2 を元画像とするテストデータを入力することにより、本研究で構築した学習モデルの評価を行った。猪苗代地区をテストデータとする学習モデルの評価結果を表 2 に示す。この表から、腐食、塗膜変状および判定対象外の分類正解率はそれぞれ 88%、80%、92%であった。なお、猪苗代地区の状況写真には、健全とするテストデータが存在しないため、精度評価から除外した。



図2 テストデータ（猪苗代地区の拡幅橋）

5. 考察

本研究で構築した学習モデルにおける誤分類について考える。はじめに、腐食が塗膜変状へ誤分類されたことについては、図3に示すような小さな腐食(11ピクセル程度)による影響と考えられる。小さな腐食画像を塗膜変状として分類する傾向が見られた。



図3 小さな腐食を含む画像例




図4 塗膜の補修を含む画像例




図5 白色化および塗膜表面の汚れを含む画像例

腐食のトレーニングデータにおいて、小さな腐食が含まれている画像は2%であり、小さな腐食を含む画像を十分に学習できていないと考えられる。

つぎに、塗膜変状が腐食へ誤分類されたことについては、図4に示すような局所的に補修が行なわれた箇所が影響していると考えられる。つまり、ブロック画像内における補修と未補修による塗装色の差異が存在することにより、塗膜変状の特徴量の抽出に影響を与えたと考えられる。また、塗膜変状が判定対象外に誤分類された原因について、白色化(色褪せ)や塗膜に付着している汚れ(砂埃)などが塗膜変状の分類正解率を低下させたと考えられる。ここで、トレーニングデータの判定対象外におけるコンクリート部材の画像は88%を占めていることから、図5に示すような灰色や白色を有する画像が多く学習されていた。図2に示したテストデータの塗膜は白色化が進んでいたこと、塗膜変状が判定対象外へ誤分類されたと考えられる。

最後に、判定対象外は他のクラスへの誤分類が見られなかったが、テストデータの判定対象外におけるコンクリート部材のブロック画像は95%(北部モデルのトレーニングデータは88%)となっていることから、猪苗代地区の判定対象外を正しく分類することが可能であったと考えられる。

本研究と同様の手法による既往の成果^{2)~4)}においては腐食の分類正解率が67%~83%であることから、既往の成果と比較して本研究で構築した学習モデルは腐食の分類精度が高いことが分かった。これは、既往の成果におけるトレーニングデータ数と比較して、5~11倍多いことが分類正解率の向上に寄与していると考えられる。

6. まとめ

本研究では、平成28年度に福島県が実施した道路橋点検結果における福島県北部(県北地区および会津地区)の状況写真を使用して、ディープラーニングによる学習モデルを構築し、鋼橋の腐食箇所の検出を試みた。これら地区からなる福島県北部における学習モデルの評価結果から、腐食の分類正解率は88%であった。

今後の課題は、ブロック画像内の小さな腐食および局所的な塗装の補修による分類正解率への影響を評価する。さらに、トレーニングデータの判定対象外には、コンクリートの打継ぎおよび打重ねといった直線構造を持つ画像が存在する。これらは、特徴量の抽出において、腐食の誤分類を引き起こす要因となる可能性がある。そのため、打継ぎおよび打重ねが分類精度に与える影響を検討する。

謝辞

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くと共に、同県産学連携ロボット研究開発支援事業の助成を受け、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、ここに記して、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/yobol_1.pdf.
- 2) 中村和樹, 子田康弘: 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, 土木学会平成 30 年度全国大会第 37 回次学術講演会, pp. 849-850, 2018.
- 3) 佐藤直人, 中村和樹, 和泉勇治, 子田康弘: ディープラーニングを用いた鋼橋における腐食箇所の検出に関する検討 日本リモートセンシング学会第 67 回学術講演会, pp. 181-182, 2018.
- 4) 佐藤直人, 中村和樹, 和泉勇治, 子田康弘: Deep learning を用いた福島県における鋼橋の腐食検出, 日本リモートセンシング学会第 67 回学術講演会, pp. 59-60, 2019.
- 5) A. Krizhevsky, I. Sutskever and G.E. Hinton: Proc. Advances in Neural Information Processing Systems 25, NIPS foundation, pp.1090, 2012.