

機械学習による橋梁撮影画像からの損傷状況および損傷原因の推定

東京大学大学院 学生会員 ○山根達郎 東京大学 正会員 全邦釘 愛媛大学 正会員 森脇亮
愛媛大学大学院 非会員 渡部達也 愛媛大学 正会員 藤森祥文

1. はじめに

近年、我が国ではインフラ構造物の高齢化が問題となっている。このことから、近年幅広い分野で高い性能を発揮している Deep Learning をインフラの維持管理に活用し、維持管理の効率化を図る研究が進められている。

情報工学分野では、写真から状況を説明する文章を生成する画像キャプション生成の研究が Deep Learning によって近年大きく進展している¹⁾。維持管理分野では単純な画像分類 AI を用いる研究は多いが、橋梁の撮影画像には損傷の有無以外にも部材や損傷の種類など多くの情報が含まれており、単純な画像分類 AI ではこれらの情報は取得しづらい。そこで、画像から文章を生成することで、複雑な情報を的確に取得できるようになる。

また、ブラックボックスとされる Deep Learning による判断を可視化することで、説明性が求められる実際の現場への導入を円滑にするだけでなく、モデルの精度改善のための方針も立てやすくできると考えられる。以上のことから、本研究では、画像から損傷の種類や損傷部材についての文章を生成できる Deep Learning モデルの構築を行うとともに、文章を生成する際に入力画像のどの部分を重要視したのかを可視化することを目指す。

さらに、撮影画像から部材や損傷の情報が得られれば、橋梁の損傷原因に関する既存の知識と連携させることで、損傷の原因まで推定することができると考えられる。ここで、損傷原因の推定においては、その推定理由が判断しやすいことが実際の現場への導入において重要であると考えられることから、本研究では、Deep Learning による文章生成モデルのほかに、損傷の発生部材や周辺状況などを基に損傷発生要因を推定でき、かつ推定理由が判断しやすい機械学習モデルの提案も併せて行う。

2. 損傷状況の判定

本研究では、CNN と LSTM を組み合わせることで、損傷状況を示す文章を出力できる Deep Learning モデルを構築した。本モデルは、図-1 に示すように、撮影画像とモデル自身が直前に出力した単語を入力に用いることで文章を生成する。また、CNN の畳み込み層から出力される特徴マップに対して、分類クラスから誤差逆伝播により求められる勾配を重み付けすることによって、モデルが文章の生成時に入力画像のどの部分を見ているかを可視化できるようにした。本研究では、着目領域のヒートマップを各単語の出力ごとに生成することで、部材名や損傷の種類を出力する際に画像のどこを見てモデルが判断しているのかを示す。また、学習のために、10084 枚の撮影画像に損傷状況の文章を紐付けたデータセットを構築した。キャプション中の損傷の種類は 22 種類、部材の種類は 35 種類である。また、本研究では、画像中に複数の損傷がある可能性が高い場合は、1 枚の画像から複数のキャプションを生成できるようにした。図-2 に、本研究で構築したモデルへの入力




図-1 構築した Deep Learning モデルの概要図




(a) 入力画像

主桁において、腐食が発生している。
主桁において、防食機能が劣化している。

(b) 生成された文章



『主桁』



『腐食』

(c) 単語出力時の着目領域

図-2 入力画像および出力結果

画像および生成された文章と、部材および損傷の単語を出力した時の着目箇所の可視化画像の例を示す。

本研究では、構築した文章生成モデルの精度検証のために、学習データセット以外の画像を新たに 200 枚用意して文章を生成した。このとき、入力画像に対して損傷とその損傷が発生している部材が完全に一致している文章が 1 つ以上出力された割合は、全体の 82.0%であった。今回学習に用いたデータセットには、部材と損傷の組み合わせが単純計算で 770 通り考えられることから、高い精度で文章が生成できているといえる。また、この程度の精度が確保できれば、例えばドローンなどを用いて橋梁全体を撮影することで損傷の大まかなスクレイピング等も可能になり、点検時により注視すべき箇所の目星などをつけることもできると考えられる。

3. 損傷原因の推定

損傷原因の推定においては、各損傷原因について一般的に人間が原因の推定を行う際に確認する項目（確認項目）をいくつか対応付け、確認項目を満たしているかによって判断を行う。例えば、腐食の原因の一つの「伸縮装置からの漏水」の確認項目は、「伸縮装置が破損しているか」などである。ここで、各損傷原因 $C = \{C_1, C_2, \dots, C_k\}$ のうち、 i 番目の損傷原因 C_i について、 C_i における確認項目 I_i が J 種類あり、 I_i に対応する重みが w_i と表されるとすると、 C_i の点数が式(1)によって求められる。

$$C_i = \sum_{j=1}^J w_{ij} I_{ij} \quad (1)$$




図-3 各確認項目に対応する重みの更新基準

式(1)により求められた各損傷原因の点数から損傷原因を推定することができる。また、推定された損傷原因に対して各重みを参照すれば、判定結果に寄与した確認項目がすぐに判断でき、容易に推定理由が判断できる。

本研究では、この重みを学習によって決定する。そこで、実際の橋梁の点検調査を基に、損傷種類と部材、および損傷原因等を対応付けた学習データを作成した。作成した学習データにおける損傷部材の数は 1600 個である。本研究では、腐食の損傷原因を 14 種類の中から推定するように学習を行った。学習の際には、学習データからランダムに選んだデータをモデルに入力し、図-3 に基づきモデル内の重みが更新される。本研究では、学習データの 70% を学習に使い、残りの 30% で精度評価を行った。ここで、実際の橋梁の損傷は、様々な原因が複合的に作用して発生するため、可能性の高い損傷原因をいくつか出力することで実用的な運用が可能になると考えられる。よって本研究では、可能性の高い上位 3 つの損傷原因を出力した。その結果、最も確率が高い損傷原因として出力された結果が正解と一致している割合は 62.6%、出力した損傷原因の中に正解と一致している損傷原因が含まれる割合は全体の 86.3%に達した。

4. おわりに

- 1) 橋梁撮影画像から、部材と損傷を完全に正しく説明した文章を高い精度（一致率 82.0%）で生成できる Deep Learning モデルを構築した。また、文章生成時にモデルが着目している領域の可視化を行った。
- 2) 損傷発生部材や損傷の周辺状況などを基に損傷原因を推定する機械学習モデルを提案した。正解と一致した損傷原因が推定された割合は 86.3%と高く、判断に寄与した要因が非常に簡単に判断できる。
- 3) 本研究の成果を用いることで、AI を用いて予め点検箇所の目星をつけることや、経験の浅い技術者に対する点検補助などが可能になると考えられる。将来的には、撮影した画像を基に損傷状況や原因を判断し、自動的に対策の立案を行うことも視野に入れることができ、維持管理の省力化につながると考えられる。

参考文献

- 1) Andrej Karpathy and Li Fei-Fei: Deep visual-semantic alignments for generating image descriptions, In CVPR, pp.3128–3137, 2015.