

RNN による橋梁撮影画像からの損傷状況言語化

愛媛大学 学生会員 ○木原 拓海 愛媛大学 正会員 全 邦釘
愛媛大学大学院 学生会員 山根 達郎 愛媛大学 非会員 渡部 達也

1. 背景・目的


我が国における橋梁の整備は高度経済成長期に集中的に行われた。また、橋梁の耐用年数は約 50 年と言われており、耐用年数を超過している橋梁は 2033 年には全体の約 67%まで増加するとされている¹⁾。このことから、国土交通省は「メンテナンスサイクル」の構築を推進していくと提言したが、その実施には莫大な費用と労力が必要であるといった課題もあるため、効率的な維持管理手法の確立が求められている。このような背景から、近年幅広い分野で活用されている Deep Learning の技術を維持管理に活用する研究が行われている。Deep Learning は、画像認識や言語処理などのタスクにおいて高い精度を誇ることが知られており、特に言語処理においては、画像内の状況を説明する文章を自動生成する、画像キャプション生成に関する研究が注目されている。ここで、維持管理のために画像から文章生成を行う場合、画像の情報を文章で表現することで、まず、システムを使う事業者が理解しやすいという利点がある。また、人間は日常的に言語から情報を取得するため、言語化することで情報処理速度や理解度が向上すると考えられる。さらに、文章で表現することでほかの文章と連携させることができるため、画像のみを扱うよりも活用の範囲が広がると考えられる。このことから、本研究では、撮影画像をもとに、橋梁の損傷状況を説明する文章を自動生成する手法の構築を目的とする。

2. モデルの構築

既存の一般的なキャプション生成用データセットは維持管理分野に特化したものではないため、橋梁の損傷を説明する文章を生成することはできない。そこで本研究では、橋梁の損傷部分を撮影した画像を用いて学習データを作成した。キャプションは、点検調書を参考に、ひび割れ、鉄筋露出、遊離石灰、漏水、腐食といった損傷状況を判断して設定した。1 枚の画像に数種類の損傷が見られる画像や 1 種類の損傷が複数の部材に発生している画像については、1 枚の画像に対して 1~4 文のキャプションを付与した。作成したデータをもとに、CNN、RNN と呼ばれるニューラルネットワークを用いて、損傷状況を文章で説明するモデルを構築した。

3. 結果

構築したモデルによるキャプション生成結果の一例を図-1 および図-2 に示す。図に示すように、単一の損傷のみならず、複数損傷が発生している画像については、複数のキャプションが生成できていることが分かる。ここで、複数のキャプションを生成した場合、一番上にあるキャプションほど有力であることを意味する。一方、図-2(b)のようにキャプション生成が上手く行えていない場合もあった。図-2(b)のキャプションで一番有力



(a)鉄筋露出

(b)遊離石灰

図-1 単一キャプション生成例

(a)剥落・鉄筋露出

(b)生成失敗例

図-2 複数キャプション生成例

とされているのは「地覆における遊離石灰の発生」だが、実際に起きているのは二番目、三番目に生成された「高欄のコンクリートの剥落」である。

また、損傷が1種類の画像において、ひび割れ、鉄筋露出、遊離石灰、漏水、腐食の5種類の損傷について、各50枚、計250枚の画像に対してキャプション生成を行ったときの、生成されたキャプションの正解との一致率を示した表を表-1に示す。表から、画像における部材を正しく認識できている割合は全体の80.4%、損傷を正しく認識できている割合は全体の82.0%、そのどちらも正しく認識している割合は70.0%であり、ほとんど正しく認識していることが分かる。

さらに、学習に用いた画像の枚数とキャプション生成の精度の関係についても検証を行った。図-3に、損傷を鉄筋露出だけに限定した場合の、学習用画像の枚数を増やしたときのキャプション生成の成功割合の推移を示す。図から、画像枚数を増やすほどキャプション生成の成功率が上がっていることが読み取れる。

表-1 損傷が1種類の画像についての一致率

(単位：%)				
損傷	部材	損傷	すべて一致	すべて不一致
ひび割れ	78.0	86.0	72.0	8.0
鉄筋露出	80.0	80.0	66.0	6.0
遊離石灰	88.0	70.0	64.0	6.0
漏水	82.0	84.0	74.0	8.0
腐食	74.0	90.0	74.0	10.0
平均	80.4	82.0	70.0	7.6




図-3 画像枚数によるキャプション生成成功率の推移

4. 考察

本研究で行った方法により、概ね高い精度でキャプション生成を行うことができたものの、図-2(b)に示すように、上手くキャプション生成ができなかった場合もあった。図-2(b)においては、学習データに高欄と地覆が同時に含まれている画像が多くあったため、高欄と地覆をきちんと識別できていないと考えられることや、コンクリートの剥落部分が白く見えるため、遊離石灰と混同したことが要因と考えられる。一方、図-3に示すように、学習データの枚数を増やすことによってキャプション生成の成功率は上がる傾向にあるため、学習データをさらに増やすことでこのような誤認識を減らし、正しく部材や損傷を予測できるようになると考えられる。

5. 結論および今後の展望

本研究では、CNNとRNNを用いて橋梁の損傷画像からその損傷状況を説明する文章の生成に成功した。生成結果から、損傷が1種類の画像の場合、70%以上の割合で正しい文章を生成することができた。また、損傷が複数存在する画像についても、複数の文章を生成することで損傷を説明する文章を生成することができた。

また、将来的には、対象となる橋梁を橋梁点検の要領で撮影し、その画像から損傷状況のキャプションを自動生成した後、生成した文章をもとに、損傷発生要因の仮説、及び対策を提案する文章の自動生成を目指す。これらを可能にすることで、損傷の現状を把握、理解、納得したうえで、迅速に適切な対策の実行に移ることができると考えられる。そのために、学習データを増やし精度の向上を図るほか、それぞれの損害の程度を判定するために、点検調書をもとに判定区分ごとに分けるモデルも用意する。判定区分はⅠ健全、Ⅱ予防保全段階、Ⅲ早期措置段階、Ⅳ緊急措置段階の4段階で評価することを目標とする。次に、今まで蓄積された土木的知見と橋梁の周辺環境の情報から損害の原因を予測し、修繕優先度、修繕方法が提案できるようにする。

6. 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 (2019/03/07アクセス)