

深層学習によるトンネルの損傷検知に関する取組

川城 研吾[†] 榎本 真美[†] 安田 亨[†] 吉岡 正泰[†]

パシフィックコンサルタンツ株式会社[†]

1. はじめに

橋梁やトンネル等の社会インフラの老朽化，その維持管理が大きな課題となっており，産官学が連携し取組を進めているところである。

我が社においても走行しながら高解像度カメラと高精度レーダーを用い現場情報収集する「走行型計測車両（以下，MIMM-R という）」を開発し，手書き等で実施されていた従来作業の大幅な合理化を図っている。しかし，MIMM-R で計測した画像の解析にも未だ多くの手間と労力を要しているのが実情である。

筆者らは，さらなる負担軽減に向け，深層学習による損傷検知に取り組み，評価を行っているところである。実施した取組のうち，本稿では畳み込みニューラルネットワーク（Convolutional Neural Network, CNN）を用いたひび割れ検知の取組について報告する。

2. ひび割れ判定モデルの構築

MIMM-R を用い自社で取得したトンネル約300 スパンのトンネル展開画像を元に学習用のデータセットを作成するとともに，当該データセットをCNNで学習することで，ひび割れの判定モデルを構築した。

(1) 学習用データセット

トンネル展開画像に対し，ひび割れ幅（0.3～0.5, 0.5～1.0, 1.0～）毎に分類し，従来手法（近接目視・打音検査）を通じて作成された損傷図（図2参照）を参考に，アノテーション（図4参照）を付与することで学習用データセットを作成した。

(2) モデル構築

アノテーション付きのトンネル展開画像をメッシュ分割し，ひび割れ幅の分類ごとにひび割れ判定モデルを作成した。

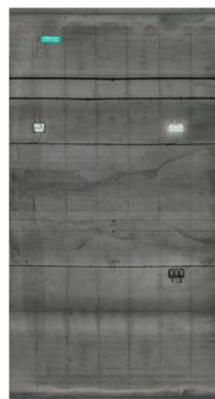


図1 トンネル展開画像の例

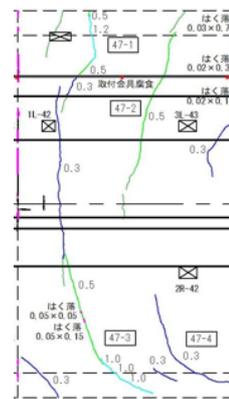


図2 損傷図の例



図3 展開図とアノテーション画像の合成画像

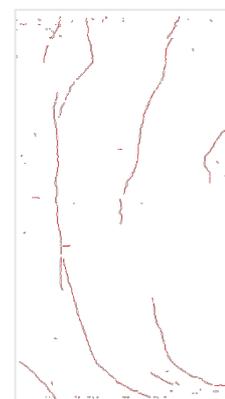


図4 アノテーション画像の例

表1 モデル構築手法

手法	ネットワーク	メッシュ単位
手法1	GoogLeNet ¹⁾	224×224 ピクセル
手法2	VGG ²⁾	32×32 ピクセル

モデル作成に際しては，表1に示すとおりメッシュ分割単位及びバックボーンネットワークが異なる2通りのモデルを構築した。

3. 検証手法

検証用の展開画像に対し，前項の2種類のひび割れ判定モデルを用いひび割れを推論するとともに，その結果をヒートマップ形式で可視化することで，適切にひび割れ位置が抽出できるか

Study on Damage Detection of the Tunnel using Deep Learning

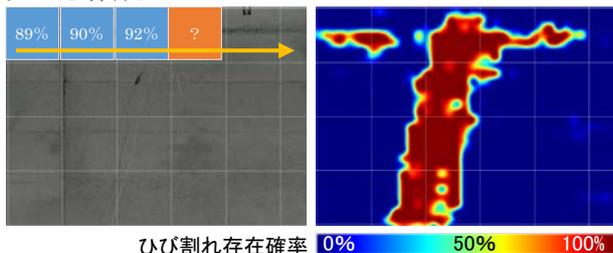
[†]Kawashiro Kengo [†]Enomoto Mami

[†]Yasuda Tooru [†]Yoshioka Masayasu

[†]Pacific Consultants Co., LTD

評価を行った。

なお、展開画像はサイズが大きく（約 5,500×13,500 ピクセル）、そのままモデルに投入することが困難であったことから、展開画像は等間隔（手法1, 2で設定したメッシュ単位）に分割し、分割画像単位でモデルに入力・推論していくスライディングウインドウと呼ばれる手法を用いて、分割画像毎に推論結果を取得することとした。その後、分割画像を統合しヒートマップを作成した。



ひび割れ存在確率 0% 50% 100%
図5 スライディングウインドウを用いたヒートマップ作成イメージ

4. 検証結果

手法1, 手法2で作成したヒートマップ画像と展開画像・アノテーション画像を比較し、ひび割れが正しく検出できているか確認した。

出力例は図6に示すとおりである。

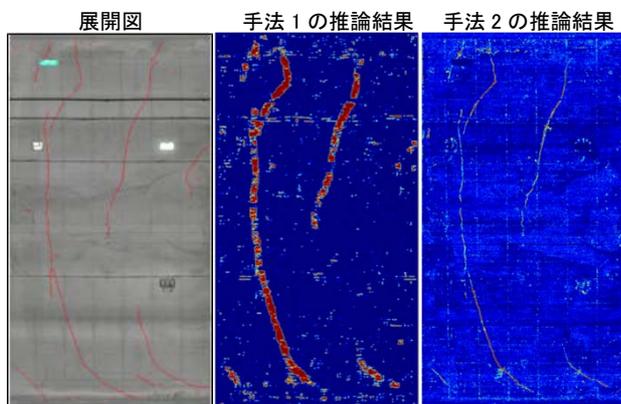


図6 推論結果の例

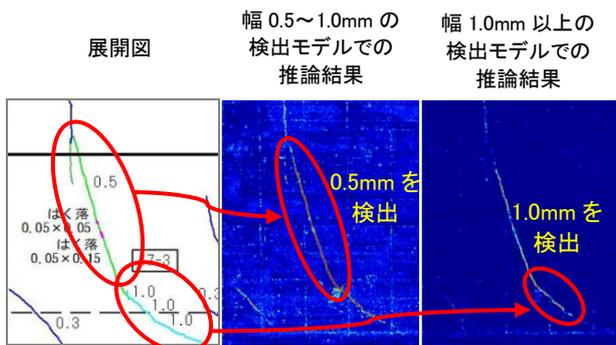


図7 手法2によるひび割れ幅の推論例

手法1の結果は、概ねひび割れを検知しているが、認識領域が広く、ひび割れ周辺が大きく検出されている。認識領域を小さくした手法2は、手法1に対し検出率は下がるがひび割れの位置がより特定しやすい結果が得られた。

これを踏まえ、手法2では更に、ひび割れ幅の検知が可能か検証した。

確認した結果、0.5mm~1.0mm及び1.0mm~のひび割れについて、相応の推論がされていることが確認できた（図7参照）。

5. 考察

今回採用した手法では、目視で明らかにひび割れと判断可能な部位は、概ね検知可能であることが確認できた。また、メッシュ単位を小さくすることでひび割れ幅の検知も可能であることが確認された。

一方、アノテーションの誤記入（実画像とのズレ等）や、教師データの不足（例：目地や他種の損傷との混在）により、推論漏れ、ひび割れ以外の箇所をひび割れとして推論する等の誤検知も確認された。

上記は、より多くの場面・種類のひび割れ画像を用いるとともに、正確な教師データを作成することで改善できると見込んでいる。

6. おわりに

AIを活用した社会インフラの維持管理は、国でも推進³⁾することとなり、その中で教師データ整備も計画されている。当初自社のデータのみでモデル構築を進めてきたが、国で整備されるオープンなデータも活用することで、本取り組みで構築したモデルの精度向上が期待できる。

また、現場からは「各損傷の適切な診断評価」も求められており、本手法に加え、よりセグメンテーション・クラシフィケーションに適した手法等を並行して検討し、現場への展開・作業効率化を図っていきたいと考えている。

最後に本取り組みに多大なる支援を頂いた（株）UEIに、この場を借りて謝意を表します。

参考文献

- 1) C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich. Going deeper with convolutions. In Proc. of CVPR, 2015.
- 2) K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. In Proc. Of ICLR, 2015.
- 3) 国土交通省 報道発表「AI開発支援プラットフォームの開設準備WGの設置」, 2018.7.27