

# (50) MIMM-R で取得したトンネル画像への ディープラーニング適用に関する取り組み

川城 研吾<sup>1</sup>・安田 亨<sup>2</sup>・榎本 真美<sup>3</sup>

<sup>1</sup> 正会員 パシフィックコンサルタンツ(株) 情報システム部 (〒101-8462 東京都千代田区神田錦町 3-22)

E-mail: kengo.kawashiro@ss.pacific.co.jp

<sup>2</sup> 正会員 パシフィックコンサルタンツ(株) 交通基盤事業本部 (〒101-8462 東京都千代田区神田錦町 3-22)

<sup>3</sup> 国立研究開発法人 土木研究所 技術推進本部 先端技術チーム (〒305-8516 茨城県つくば市南原 1-6)

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られている。我が社でもトンネル点検用に走行型計測車両「MIMM-R」を導入し，点検の合理化を図っているところである。しかしながら，後工程では多くの作業負担が生じているのが実情である。筆者らは，当該課題の解決に向け，複数のディープラーニングの手法を用い，これらの課題解決に向けた技術開発に取り組んでいる。

本稿はこれまでの技術開発で得られた成果について報告するものである。

**Key Words:** MIMM-R, CNN(convolutional neural network), GAN(generative adversarial networks), semantic segmentation ,mask R-CNN

## 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られている。弊社では，早くからトンネル点検の合理化に向け，「走行型計測車両（以下，MIMM-R<sup>1)</sup>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ところである。

しかしながら，計測の後工程で実施される目視による損傷箇所の確認や損傷展開図の作成等において，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，上記課題解決の手段としてディープラーニングに着目し，後工程の作業負担軽減に向けた技術開発を行っている。本稿は，これまで弊社が実施してきた技術開発について内容を示すとともに，その評価について述べるものである。

## 2. 取り組みの全体像

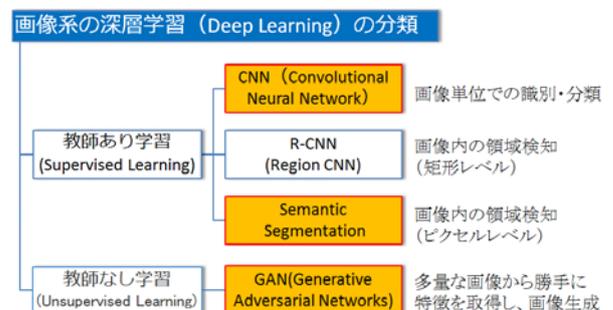
筆者らは，後工程の人力で実施されている作業の自動化・効率化が重要であると考え，以下の点を解決することを目標とした。

<解決すべき課題>

- ・ 多量な点検画像からの損傷箇所抽出
- ・ 損傷種別の分類
- ・ 損傷展開図の作成支援

なお，AI 技術は日進月歩で進化し，様々な手法が開発されているが，今回の技術開発領域である「画像系のディープラーニング技術」は概ね図 1 の通り大別できる。

解決すべき課題と画像系 AI 技術の特性から，表 1 に示す通り適用手法を選定し，試行検証を行うこととした。



※黄色ハッチング：弊社の技術開発で取り扱った技術

図 1 画像系ディープラーニングの分類 (技術体系)

### 3. CNN を用いたひび割れ箇所の検知

多量な点検画像から損傷箇所を抽出することを目指し、自社で取得済みのトンネル展開画像を用い、ひび割れ検知モデルの構築し、検知精度を評価した。

具体的な実施内容は次の通りである。

#### (1) 教師データ

目視点検で作成した損傷展開図を元に、ラベル付けを行った。この際、ひび割れ幅の推論も目指し、①0.3mm～0.5mm、②0.5mm～1.0mm、③1.0mm 以上で分類し作成した。

#### (2) モデル構築

上記で作成した教師データを表 2 の“画像サイズ”単位で整理したものを教師データとし、“バックボーンネットワーク”を用いた CNN でモデル構築を行った。

#### (3) 構築した損傷検知モデルの検証

構築したモデルに対し、まずはひび割れ・損傷等の検知が可能であるかの検証を行った。

表 1 解決すべき課題と適用技術

解決すべき課題	適用技術
多量な点検画像からの損傷箇所抽出	CNN(Convolutional Neural Network)
損傷種別の分類	//
損傷展開図の作成支援	Semantic Segmentation, GAN(Generative Adversarial Networks)

表 2 モデル構築手法

手法	バックボーンネットワーク	画像サイズ
手法 1	GoogLeNet <sup>※1</sup>	224×224 ピクセル
手法 2	VGG <sup>※2</sup>	32×32 ピクセル

※1 2014 年の ILSVRC で提案. 層の数(16 層)が多いことが特徴

※2 2014 年 ILSVRC の優勝モデル. 複数の畳み込み層や pooling 層から構成される Inception モジュールを重ね、一つの CNN を作り上げていくことが特徴

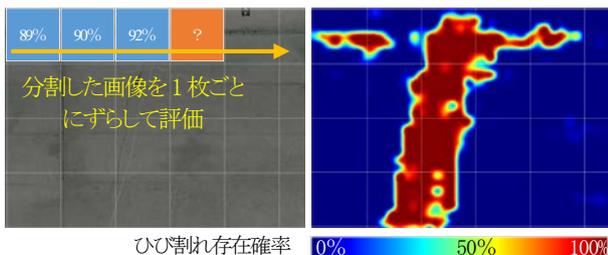


図 2 スライディングウィンドウを用いた評価用ヒートマップの処理イメージ

#### a) 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評価を行った。

具体的には、展開画像を等間隔(手法 1, 2 で設定したメッシュ単位)に分割し、“スライディングウィンドウ”と呼ばれる手法(分割した画像毎に損傷検知モデルで推論する手法)で、個別画像毎の推論を行った後に、推論結果を結合し、ヒートマップを作成した(処理イメージは図 2 を参照のこと)。

#### b) 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 3 に示すとおり)。

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。

図 4 にひび割れ幅の推論結果の例を示す。この場合、0.5mm～1.0 mm 及び 1.0 mm 以上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ことがわかる。

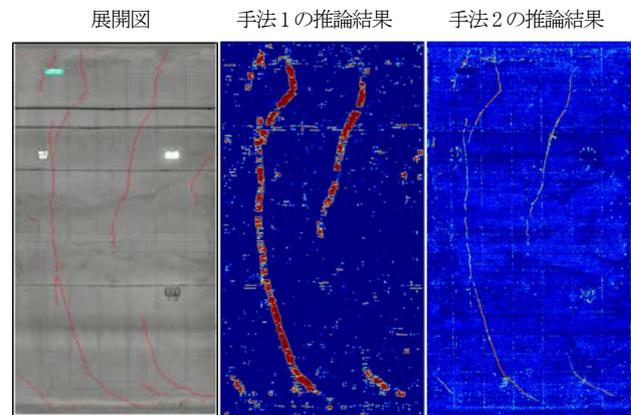


図 3 推論結果の例

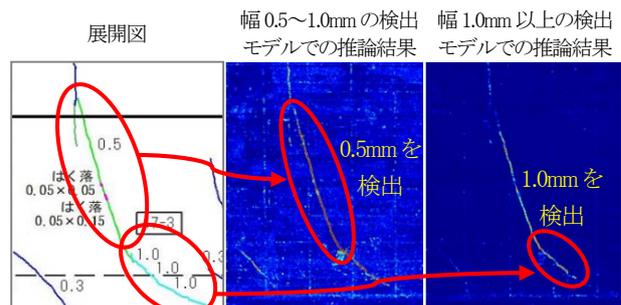


図 4 手法 2 によるひび割れ幅の推論例

#### (4) 評価

CNN によるひび割れ検知は、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。

ただし、当該手法は領域レベルの検知にとどまるため、損傷展開図の作成支援を実現するには物足りない。

そこで筆者らは“ひび割れそのもの”の検知を目指し、セマンティック・セグメンテーション (Semantic Segmentation) と GAN (Convolutional Neural Network) によるピクセル単位でのひび割れ検知を試行した。

次にこれらの取り組みについて示す。

### 4. セマンティック・セグメンテーションによるひび割れ検知

セマンティック・セグメンテーションは画素単位でラベル付けを行った教師データを学習させることで、画素単位での物体検知・分類を行うディープラーニングの手法である。筆者らは、当該手法を用い、ピクセル単位でのひび割れ検知を行うことで、損傷展開図の作成の省力化が図れると考え、当該手法について試行を行った。

#### (1) 教師データ

CNN で実施した作業と同様に、適当なサイズに分割し、ラベル付けを行った。なお、ラベルの分類についても CNN と同様の分類を行った。なお、教師データの作成イメージは図 5 に示す通りである。

#### (2) モデル構築手法

いくつかのセマンティック・セグメンテーションの手法について、評価用モデルを構築し、性能比較を行った。

比較の結果、Facebook 社で開発された Mask R-CNN (ICCV 2017 Best Paper に選出された手法) を選定し、バックボーンネットワークや画像サイズ、データ拡張の条件を変えた 2通りの手法 (表 3 に示す通り) で実施した。

表 3 モデル構築条件

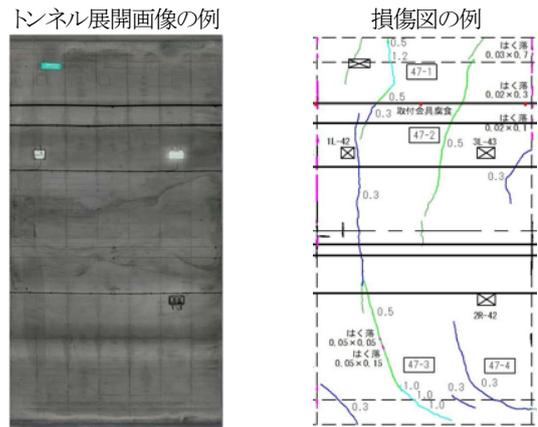
項目	条件-1	手法-2
バックボーンネットワーク	ResNet <sup>※1</sup>	ResNeXt (ResNet の発展モデル)
データ拡張	無し	コントラスト変更, ガンマ変更, ガウスノイズ, インパルスノイズ
画像サイズ	メッシュ分割 (512x512)	メッシュ分割 (512x512, 800x800 の 2通り)

※1 ResNet: Residual Networks の略。ILSVRC2015 優勝モデル

#### (3) 構築した損傷検知モデルの検証

ひび割れ検知モデルの検証結果を図 6, 図 7 に示す。いずれの手法も高い精度を得ることができなかった。

原因について調査したところ、本来検知されるべきひび割れが検知されないというケースが散見された。そのため、今一度教師データをチェックしたところ、教師データ自体にラベルのズレ・誤入力が散見された。これらの状況を勘案すると、教師データの精度が検知精度に直接的に影響していると想定された。



展開図とラベル画像の合成イメージ



教師データの作成イメージ (画僧単位でのラベル付与)

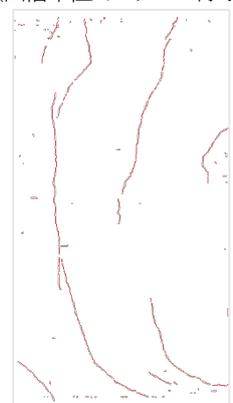


図 5 教師データの作成イメージ

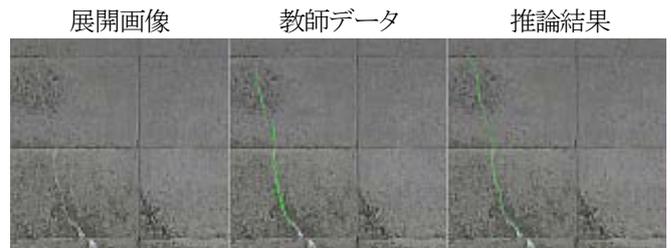


図 6 ひび割れの推論例

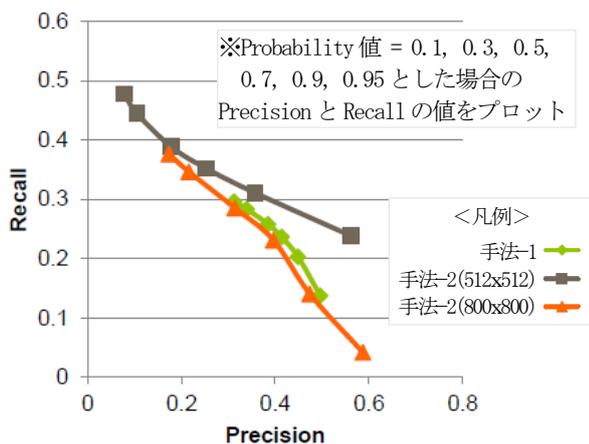


図7 ひび割れ推論結果の精度

#### (4) 評価

セマンティックセグメンテーションにより画素レベルの損傷検知の実現可能性は確認することができた。しかしながら実用に耐えうる精度を確保するためには、正確な教師データが不可欠であることが確認された。

### 5. GANによるひび割れ検知

GAN (Generative Adversarial Networks, 敵対的生成ネットワーク) は、データセットから特徴を学習することで、実在しないデータを生成したり、存在するデータの特徴に沿って変換する仕組みを有しており、教師データ無しで学習可能な手法であることから注目を浴びている手法である。筆者らは、当該手法を応用することで、写真からひび割れの画像生成 (画像変換) を行えるのではという仮説を立て、検証を行った。

#### (1) 学習用データ

筆者らは、先のセマンティック・セグメンテーションを実施するために作成したラベル画像と点検時に取得した写真のペア画像 (具体的なイメージは図8を参照) を生成した。

#### (2) モデル構築手法

上記で準備した学習用データ (100 セット) を代表的なGANのアルゴリズムである pix2pix (NVIDIA とカリフォルニア大学バークレー校の研究者が開発) を用い、エポック毎に精度を確認しながら、学習を実施した。

#### (3) 構築した損傷検知モデルの検証

200 エポックまで実行すると、概ね正しい画像が生成される状況となった (図9参照)。

しかし、200 エポック以上実行しても、精度は向上せず収束する結果となった。

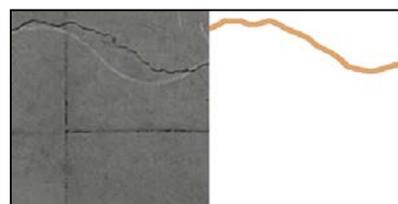


図8 点検写真とラベルデータのペア画像

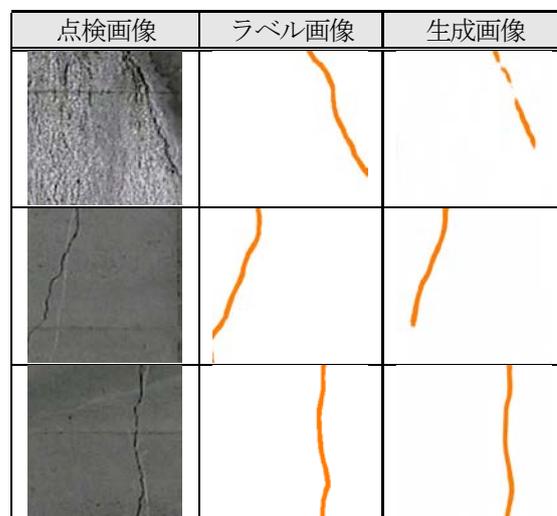


図9 GANによるひび割れ検出結果の例

#### (4) 評価

完全な結果では無いが、GANでもひび割れ領域の検知が可能であることが確認された。200 エポックで精度が収束していたが、これは学習用データが100 セットとそれほど多くはなかったことが原因と想定された。

また、セマンティック・セグメンテーションでデータ精度の課題を示したが、GANを実行する上でも、検出精度に影響を及ぼしていた可能性があると考えている。

### 6. 結論と今後の展開

今回、大きく3通りの手法でひび割れ検知の取り組みを行い、検知自体はいずれの手法でも相応に適用性があることが確認された。一方、教師データの質がモデルの性能に大きく影響することも確認された。

これを踏まえ、現在弊社ではより精緻な教師データの作成と当該データを用いたモデル構築・検証を進めているところである。

これにより、実用性が担保されていることが確認された後、実務へ展開を図る計画としている。

#### 参考文献

- 1) 安田 亨, 山本 秀樹, 重田 佳幸: 走行型高速3Dトンネル点検システム MIMM-R (ミーム・アール), 日本ロボット学会誌, 34 巻 9 号, pp.589-590, 2016