

AIを用いた道路施設の 変状箇所抽出モデルの開発

えのもとまみ ふじわらひろし まつばらけんじ しげたよしゆき やすだとおる
榎本真美¹・藤原広志¹・松原健二¹・重田佳幸¹・安田 亨¹

¹パシフィックコンサルタンツ株式会社（〒101-8465 東京都千代田区神田錦町3-22）

インフラ老朽化が進み効率的な維持管理が求められていることを背景に、トンネルの走行型計測車両(MIMM-R)によって取得した300スパンの画像データと点検後の損傷図を教師データに使用して、深層学習を用いたひび割れの変状検出を行った。深層学習の一種である畳み込みニューラルネットワークを用いて、展開画像に対しひび割れの有無の判定を行い、変状箇所を赤く示すヒートマップを作成した結果、変状箇所の特定とひび割れ幅の分類が可能であった。また、敵対的生成ネットワークを用いて、ひび割れの形状を示す画像を高い精度で生成が可能であることを確認した。

Key Words : 深層学習, 畳み込みニューラルネットワーク, 敵対的生成ネットワーク, 画像認識, MIMM-R

1. はじめに

橋梁やトンネルなどインフラの老朽化が進むなか、効率的な維持管理が近年の課題となっている。例えばトンネル点検では、現在、幅0.3mm程度のひび割れを判別できる走行型計測車両(MIMM-R)が導入され、従来の手作業によるスケッチより効率的に計測することが可能となった。しかし、MIMM-Rの計測によって得られた画像を解析し、CADソフトを使って損傷展開図を作るため、未だ多くの手間と労力を要している。

MIMM-Rで計測した後、迅速に展開図を作成し、損傷箇所に対して近接目視による点検と的確な健全度診断を行い、効率的に点検調書を作成することが求められている。それによって、素早い対応と適切な補修が可能となり、維持管理コストの削減が期待できる。

そこで、本研究の目的は、点検診断支援にAIを活用して効率を図ることである。具体的には、MIMM-Rに搭載されたカメラ画像と計測データ、及び、深層学習による画像認識技術を活用して、トンネルの変状位置や形状を自動的に検出するモデルの開発を行った。深層学習は、明確なルール化が難しい特徴を自動的に抽出することが可能な技術である。本稿では、トンネルのひび割れにおける畳み込みニューラルネットワーク(CNN)と敵対的生成ネットワーク(GAN)による変状検出結果の例を報告する。

2. 畳み込みニューラルネットワーク(CNN) を利用したひび割れの検出

(1) CNNの概要

コンクリートのひび割れに着目し、画像認識分野で広く利用されている深層学習の一種である畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)を用いた画像認識で、ひび割れの変状抽出が可能かを調査した。

CNNモデルとは、畳み込み層とプーリング層を用いて、入力画像の特徴抽出を行い、全結合層を通して画像のカテゴリを分類するニューラルネットワークのモデルの総称である。

(2) 学習用データセット

深層学習のモデルをつくるにあたっては、抽出する変状が明瞭に映った画像を学習用データとして用意する必要があった。そこで、MIMM-Rに搭載されたカメラで取得した展開画像と近接目視・打音検査後の損傷図を使用することとした。

変状進行状況や施工年の異なる10トンネルから合計300スパンのデータを収集した。スパン毎に合成した覆工展開画像はJPEG形式で、その分解能は1.5mm/ピクセルである。

次に示すとおり、ひび割れ幅を3つに分類して、アノテーション画像データを作成した。アノテーションとは、対象となる画像データに対して正解情

報を付与したデータのことである。

ひび割れ幅の分類：

$0.3\text{mm} \leq G < 0.5\text{mm}$, $0.5\text{mm} \leq G < 1.0\text{mm}$, $1.0\text{mm} \leq G$

300スパンのデータのうち、ランダムに選んだ8割を学習データとして用い、残り2割をモデルの検証用データとした。

(3) 識別モデル

学習用データの展開画像を認識領域のピクセルサイズで分割し、各ひび割れ幅の損傷の有無を判定するモデルを作成した。表-1に示すとおり、異なる認識領域とその領域サイズに適したネットワークを用いて学習を実行し、2つの手法で各ひび割れ幅の識別モデルを作成した。

(4) CNNによる検出結果

検証用の展開画像に対し、認識領域を少しずつ

らしながら、ひび割れに分類される可能性を算出し、その結果からヒートマップを作成してひび割れの位置推定を行った。図-1に、手法1及び手法2による幅0.5~1.0mmのひび割れ検出結果を示す。ひび割れが存在する確率の高いメッシュは赤く、存在しないメッシュは青く塗ったヒートマップで示している。

手法1の結果は、ひび割れに概ね反応しているが、認識領域が広いため、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の結果は、ひび割れの位置がより特定しやすい結果となった。また、幅0.5mmの箇所に対して高い確率を示した。

表-1 各手法の概要

手法	ネットワーク	認識領域
手法1	GoogLeNet ¹⁾	224×224ピクセル
手法2	VGG ²⁾	32×32ピクセル

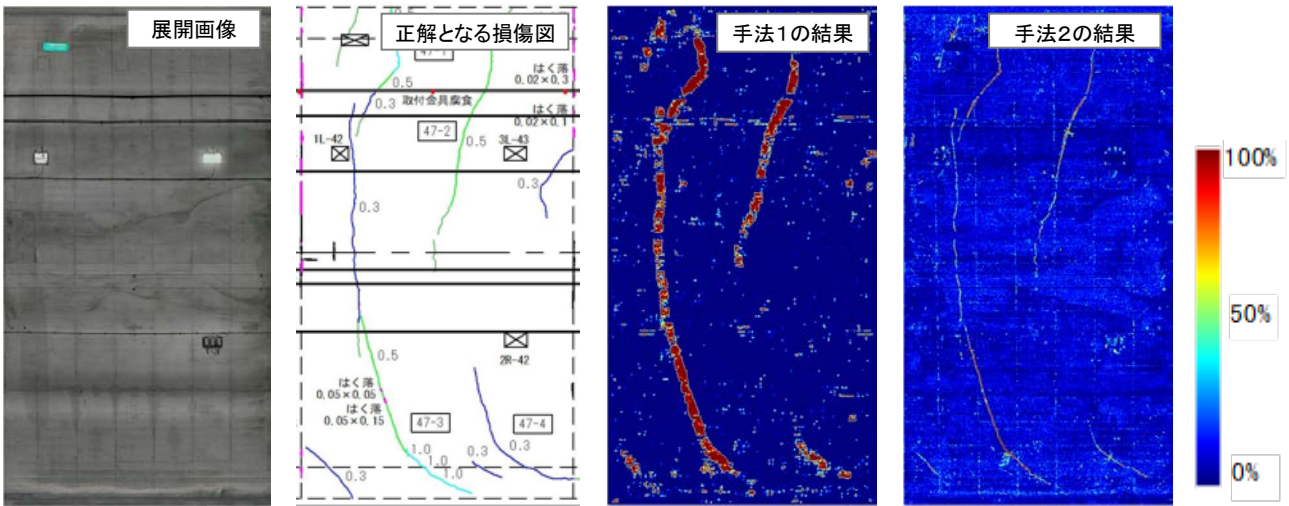


図-1 CNNによるひび割れ検出結果（ひび割れ幅0.5~1.0mmモデル）

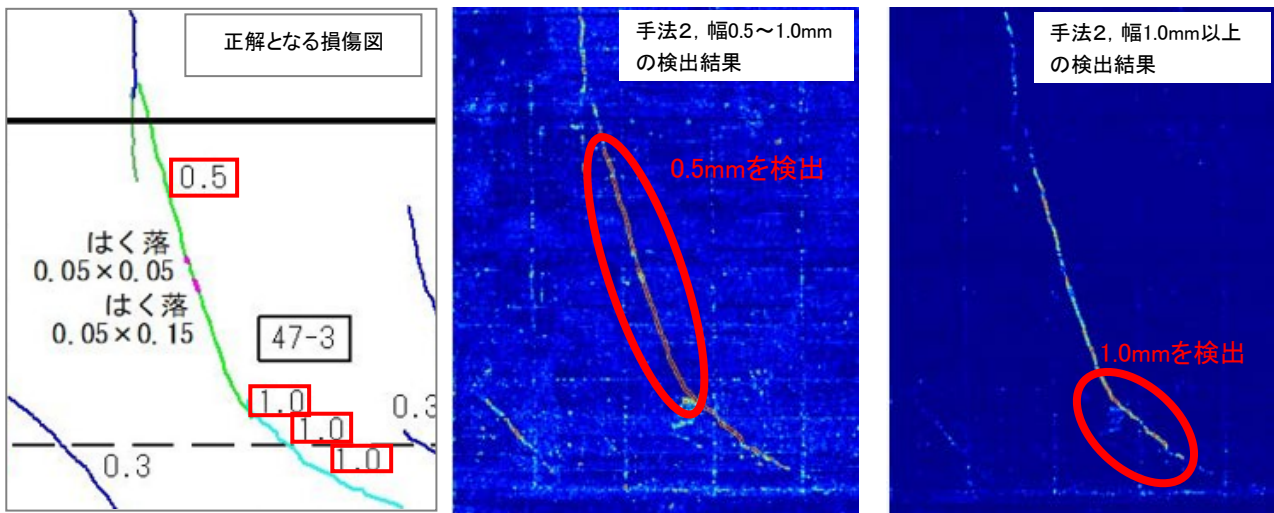


図-2 CNN手法2によるひび割れ幅0.5~1.0mmの検出結果と幅1.0mm以上の検出結果

図-2に、手法2の幅0.5~1.0mmの検出モデルと、幅1.0mm以上の検出モデルによる検出結果をそれぞれ示す。幅0.5mmのひび割れ箇所に対して、幅0.5~1.0mmモデルでは検出しているのに対し、幅1.0mm以上モデルではほとんど検出していない。また、幅1.0mmのひび割れ箇所に対して、幅1.0mm以上モデルが赤く反応していることがわかる。

これらの結果から、CNNモデルによりひび割れの位置推定が有効であることが分かる。認識領域を小さくすることで、より精度高く位置を特定できるだけでなく、ひび割れ幅の分類も可能であることを確認した。

教師データのアノテーションと実際の変状にずれが生じている場合、間違っただけの学習を行い、正確に検出できない原因となっていることが課題として挙げられる。

3. 敵対的生成ネットワーク (GAN) を利用したひび割れの検出

前章ではCNNを用いて各スパンの大きな画像に対してヒートマップを作成し、ひび割れの位置推定を行うことができたものの、より細かな線形でひび割れの形状を検出することが可能かを検証するため、GANによる変状検出を試みた。

(1) GANの概要

敵対的生成ネットワーク (Generative Adversarial Networks, GAN) とは、学習データセットからデータ分布を獲得し、画像を生成するジェネレーター (generator) と、入力学習データセット由来かジェネレーター由来かを判別するディスクリミネーター (discriminator) という2つのニューラルネットワークを同時に競争させながら学習することで、目的のデータに近い新しいデータを生成する。

今回は、GANを利用した画像生成アルゴリズムの一種「条件付き敵対的生成ネットワーク (Conditional GAN)」であるpix2pixを用いた。Isola氏らによって提案されたpix2pix³⁾は、2つのペア画像から画像間の関係を学習することで、1枚の画像からその関係を考慮した補完をしてペアの画像を生成する。ラベルから道路や建物の外観、白黒からカラー、航空写真から地図、昼から夜、線画からカラー写真を生成するといったことが可能である。pix2pixの概念を図-3に示す。

学習用データセットとして幅1mm以上のひび割れを含むカメラ画像とひび割れ箇所に色付けを行ったアノテーション画像のペア用意し、画像からアノテーション画像を生成することで、ひび割れを検出することとした。

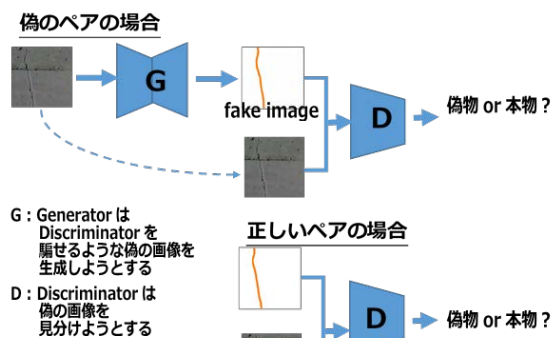


図-3 GANの概念図

(2) 学習用データセット

前章と同様に、走行型計測車両 (MIMM-R) のカメラ画像と損傷図を使用してデータセットを作成した。対象画像を256×256ピクセルに分轄後、損傷図を基にひび割れに対しアノテーション付けを行ったPNG形式データセットを作成し、図-4のように対になる画像を横に並べた学習データを作成した。




図-4 画像とアノテーションデータのペア

(3) 予備実験

ひび割れ幅が異なる教師データを混ぜて学習させるとモデルの精度が落ちる可能性があったため、まずは、明瞭にひびが画像に写っている幅1.0mm以上のひび割れを含む学習データのみを用意して、検出を試みた。その結果、変状に対して色付けした画像が生成されず、ひび割れの検出には至らなかった。

その原因として、ひび割れの存在が画像から確認できない画像や、複数の変状や施設構造物が重なった画像がデータセットに含まれていることが考えられた。これらを取り除くことで正しくひび割れの学習が可能と考え、学習データの目視精査を実施した。

(4) 識別モデル

目視精査済みのデータセット100件を用いて、学習過程をエポック毎に確認しながら、200エポックまで学習を実施した。エポック数とは、一つの教師データを何回繰り返して学習させるかの数である。図-5に50, 100, 150, 200エポックの学習過程を示す。

エポック数が少ない場合、変状を認識しておらず、目地を認識して色付けしているなど、誤った画像を生成した。しかし、200エポックの重みを利用して学習を行った場合、正しくひび割れ箇所を認識して色付けを行っており、ひび割れではない目地には色付けされていない画像を生成することができた。

エポック	入力画像	正解画像	生成画像
50			
100			
150			
200			

図-5 GANの学習過程

(5) 結果

200エポックの学習の重みづけを行ったモデルの検証結果を図-6に示す。図の左から、検証用の入力画像、比較用の正解画像、GANによって生成された画像である。ここで入力している画像は学習に利用していない画像群から選んだ検証用データである。生成画像と正解画像を見比べてみると、概ねひび割れをほぼ忠実に再現していることが分かる。

入力画像	正解画像	生成画像

図-6 GANによるひび割れ検出結果

この結果から、GANを用いたひび割れの検出は、再現性が高い結果を得ることができ、GANの有用性を確認することができた。GANを用いて自由線形でひび割れ箇所を推定することが可能といえる。ただ

し、予備実験において正しくないひび割れ画像を学習データに含むと、ひび割れ検出エラーが発生した。学習データとして、正しいひび割れ画像のみを利用することが必要である。

限られたデータ量で学習を行った結果であるため、今後教師データを増やし、より精度と汎用性の高いモデルの改善が必要である。

5. 結論

本研究の目的である点検診断支援の効率化は、AIを活用して自動化を図ることができ、一定の成果が得られた。CNNとGANを用いたひび割れ検出モデルの開発により、ひび割れの変状検出ができた。また、ひび割れ幅の自動分類も可能であることが確認できた。幅の分類については、精度にまだ課題はあるものの、今後教師データを増やすことで改善が見込まれる。

CNNモデルは、手法2のように小さな認識領域で推定すると、位置特定と同時にひび割れ幅の分類も可能であるが、計算コストや処理時間がかかってしまうことが懸念される。したがって、CNNモデルの手法1のように大きな認識領域で、概ねの変状位置を漏れがないように抽出したうえで、該当箇所に対して小さな認識領域のモデルを用いて推定を行うことで、効率的かつ正確に変状検出を行うことが考えられる。

また、GANを用いることで、ひび割れと認識する箇所を自由形で塗られた画像を生成することも有効である。分割した画像からGANで生成した画像を、再度結合させて展開図を作成することが可能である。目的やデータに応じて、アルゴリズムを選択して、変状検出を行うことが必要と考える。

6. おわりに

今後の課題として、モデルのさらなる精度向上を行い、点検や健全度判定に活用できる信頼性の評価と品質確保が必要である。さらには、画質の悪いもの、分解能が違うもの、照明などによる画相が異なるものに対しても、画像の鮮明化や画質補正をすることで判別が可能となるようなモデルの開発を行なっていく。

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) Isola, P. Zhu, J.-Y., Zhou, T. and Efros, A.A.: Image-to-image translation with conditional adversarial networks, CVPR, 2017.