

画像生成データ拡張によるひび割れ領域検出の精度分析

八千代エンジニアリング 正会員 ○関口 斉治, 八千代エンジニアリング 正会員 野田 一弘
八千代エンジニアリング 正会員 中島 道浩, 八千代エンジニアリング 非会員 安野 貴人

1. はじめに

土木構造物の維持管理には、点検による状態把握と措置の緊急性を判断する的確な診断が重要である。橋梁の老朽化が進むなか、多数の橋を5年サイクルで継続監視し、前回と今回の経年変化を効率よく自動把握するAI活用のデジタルな手順が求められている。鉄軌道・発電所等のリアルな構造物の状態と劣化の進行シナリオを予測し、最適な対処法を導出する枠組（デジタルツイン技術）が提唱されている¹⁾。AI活用には、データ、アルゴリズム、計算資源の3つが根本となる。本稿では、橋梁の損傷のうち、大多数を占めるコンクリート橋梁の「ひび割れ」を対象に、自動的に検出するアルゴリズムの精度向上をめざす。ひび割れは、乾燥収縮を含み頻繁に見られるが、この中に、緊急を要する損傷がまぎれており、的確に診断する必要がある。ひび割れの分類と物体検出のアルゴリズムは、1次検出に適するが、診断情報を提供するには情報量が足りない²⁾。ひび割れの延長と幅、形状パターンを自動的に領域検出するには、セマンティック・セグメンテーションが適している。FCN-8s, U-Net, SegNet, DeepLabv3+の深層学習が抜群の精度を発揮して以降、独自の解法に改良が繰り返されているが、精度向上に決め手を欠いている³⁾。本稿では、画像生成によるデータ拡張の手法を提案する。具体的に、コンクリートひび割れの損傷画像を生成し、教師画像とラベルの画像空間（image data space）を拡張することで、領域検出の精度向上を試みる。

2. 画像生成によるデータ拡張の方法

画像の深層学習において、従来、幾何的な移行が汎用されてきた。例えば、回転、スケール、反転、ランダムな切り取り、そして色調の変化である。これらは、初期の教師画像のRGB空間内においてvariationを与える内的データ拡張（Inner-data augmentation）といえる。反対に、初期の画像に特徴量が含まれない空

間にまで範囲を広げる外的データ拡張（Outer-data augmentation）が理想の汎用である。2つの中間に、初期の画像空間と拡張後の空間が混ざり合う共通部分の結合データ拡張（Connect-data augmentation）が実用的である。本稿では、画像生成による結合データ拡張を試みる。初期のrealな画像空間と生成後のfake画像空間は、完全には一致しないものの、ROIと背景で構成される画像に構造的な類似性（structural similarity）を有する⁴⁾。元画像よりも教師画像の空間が汎用化されて、ROIの特徴範囲が広がることで特徴が強調される利点がある。




図1 ひび割れ画像の生成方法（Tri-Label2Image）

本稿では、図1のようなL1-Conditional GAN (pix2pix)のアルゴリズムを用いて、コンクリート表面の背景特徴をCannyエッジ検出したラベルを含む、3カテゴリーの結合ラベル（Tri-Label）を入力としたひび割れ画像の生成を行う。結合の拡張として画像生成を行う際に、変化をもたせるため、0.8～1.2倍の拡大後の切り取りとランダムな反転を付加する。このように、単調に似たような画像が漫然と重複する無効なデータ拡張を防止する。画像生成の出力は、256x256画素で、200エポック学習した。図2に、ひび割れ画像の生成器の損失値の推移を示す。図3に、画像生成の入出力を例示する。

キーワード 損傷点検, コンクリートひび割れ, 画像生成, 領域検出（セグメンテーション）

連絡先 〒111-8648 東京都台東区浅草橋 5-20-8 CSタワー TEL 03-5822-6219.




図 2 ひび割れ画像生成器の学習過程 (Generator Loss)




図 3 ひび割れ結合ラベル入力 (左) と画像生成出力 (右)

3. セグメンテーション適用結果

コンクリートひび割れ画像のデータセットは、再現性を持たせるため、Web 公開のデータを用いた 5). この 1 万組から、ROI を含む 5, 500 組の損傷画像とひび割れを塗分けた 2 クラスのラベル画像を抽出した。前処理で、ペアの重複・ずれを修正し、544 組 (300x300 画素) の初期データ (initial) を抽出した。




図 4 画像生成データ拡張後における学習過程 (誤差)

訓練と試験の比率を 95:5 とし、試験画像を 27 組用意した。初期データ 544 組に領域検出の深層学習を適用し、ミニバッチ 8 で 100 エポック学習し、反復回数は 6, 800 回とした。画像生成による結合の拡張後 (+fake aug) は、544 組を増やし初期の 2 倍 (計 1, 088 組) のデータセットを用意し、100 エポック学習した (図 4)。

4. 試験画像の推論と精度分析

ひび割れ画像生成によるデータ拡張によって、ランダム抽出した試験画像に対して各領域検出器において、正解率、再現率及び F1, mIoU が精度改善した (表 1)。推論出力で緑の領域 (over-precision) が減少し、推論対象が絞り込まれている (図 5)。

表 1 ひび割れ領域検出の学習結果と精度分析

architecture	augmented dataset	precision		recall		F1-score		mean IoU	
		ROI	backgrd	ROI	backgrd	ROI	backgrd	ROI	backgrd
FCN-8s	initial	0.5383	0.8031	0.6719	0.8185	0.5897	0.8097	0.3521	0.9563
	+fake aug	0.6060	0.8396	0.7141	0.8417	0.6481	0.8396	0.3723	0.9612
U-Net	initial	0.7920	0.8938	0.8975	0.9473	0.8464	0.9264	0.4280	0.9711
	+fake aug	0.8757	0.9530	0.9542	0.9699	0.9104	0.9609	0.4885	0.9782
SegNet-VGG16	initial	0.8952	0.9415	0.9775	0.9819	0.9327	0.9608	0.5199	0.9807
	+fake aug	0.9119	0.9099	0.9951	0.9963	0.9468	0.9450	0.6299	0.9884
DeepLabv3+ResNet18	initial	0.9348	0.9751	0.9598	0.9725	0.9444	0.9734	0.5215	0.9806
	+fake aug	0.9570	0.9843	0.9735	0.9785	0.9629	0.9811	0.5395	0.9819




図 5 初期 (上) とデータ拡張後 (下) の推論出力 (FCN8s)

参考文献

1) Forstner, W., Furtner, P. et al.: Automated Infra-structure Inspection Based on Digital Twins and Machine Learning, *Proceedings of IWASHM*, 2019.

2) Chen, F.C. et al.: Real-time Video Crack Detection Based on Deep Learning for Autonomous Inspection of Nuclear Power Plant Reactors, *IWASHM*, 2019.

3) Liu, Y. et al.: DeepCrack: A New Hierarchical CNN for Crack Segmentation, *Neurocomputing*, 2019.

4) Wang, Z., Bovik, A.C. et al.: Image Quality Assessment: From Error Visibility to Structural Similarity, *IEEE Transaction on Image Processing*, Vol.13, No.4, 2004.

5) Liu, K., Han, X. et al.: Deep Learning Based Automatic Crack Detection and Segmentation for Unmanned Aerial Vehicle Inspections, *ROBIO2019*.