

Deep Learning を用いた鋼製支承画像の自動生成

大日本コンサルタント	正会員	○鬼木 浩二	大日本コンサルタント	正会員	龍田 斉
東京大学	正会員	長井 宏平	大日本コンサルタント	フェロー	横山 広
日本システムウェア	非会員	野村 貴律	大日本コンサルタント	非会員	宮川 輝幸

1. 目的

CNN(Convolutional Neural Network)等の Deep Learning による損傷画像の自動判定を試みる際に課題となるのが、損傷判定区分ごとの画像数の偏りである。国内の橋梁は、すでに架設から約半世紀が経過している橋梁がほとんどであり、損傷が進行した画像に偏る傾向がある。また、国や地方自治体が規定する橋梁点検要領は損傷箇所のみ写真記録を残すよう記載されている。このため、CNN を適用する際に、重度損傷の判定区分に偏った損傷画像のみでの学習となり、実用の精度が出にくい。そこで、GAN(Generative Adversarial Network)を用いて CNN の学習画像として利用できる疑似損傷画像の生成を試みる。GAN とは Deep Learning を用いた生成モデルの 1 種で、学習画像から疑似画像を生成することができる。本論文では、鋼製支承を対象として、CNN に有用な疑似損傷画像を GAN によって生成できるか検証を実施した。

2. 概要

GAN による鋼製支承損傷画像の自動生成の検証は、①対象部材の選定、②学習画像の作成、③機械学習、④生成画像の評価の 4 つに大別され、図-1 に示すフローに沿って実施した。以下に各手順の内容を示す。

2. 1. 対象部材の選定

鋼製支承は道路橋を構成する部材において小規模で特徴的な形状を有するため、点検調書の様式の差異により写真の内容に差が生じにくい。また、床板や主桁、横桁等の部材に比べ、識別しやすい形状(図-2(a))であると共に、GAN の学習データとして入力するエッジ画像(画像中の輝度が急激に変化する境界だけを残した画像、物体の輪郭だけ抽出したような画像になる(図-2(b))も、支承として識別できる特徴を十分に保持する傾向がある。以上の特徴より、鋼製支承を対象として検証を実施する。

2. 2. 学習画像の作成

学習データは、新潟県下市町村が新潟県橋梁点検要領¹⁾に準拠して約 10 年間実施した点検結果から、鋼製支承の損傷画像を抽出し、GAN 用に加工して作成した。以下に抽出と加工の具体内容を示す。

(1) 損傷画像選別

国土交通省が工事写真の画質について規定した「デジタル写真管理基準²⁾」は、平成 28 年 3 月の改訂まで、工事写真の解像度を約 100 万画素程度と規定していた。各自治体が策定している点検要領に写真の解像度に関する規定が無い場合、これに準ずる傾向がある。「デジタル写真管理基準」に従った損傷写真は低解像度であるため、鋼製支承と他部材との境界が不鮮明となり、支承の形状が識別しにくい。GAN による生成画像の精度向上の観点から、このような画像は除外した。




図-1 検証フロー



(a) オリジナル (b) エッジ画像

図-2 鋼製支承

キーワード 橋梁点検、鋼製支承、画像処理、Deep Learning

連絡先 〒330-6011 さいたま市中央区新都心 11-2 大日本コンサルタント株式会社 TEL048-615-2229

(2) 支承部分の切り出し

鋼製支承の損傷画像には、支承の周辺に、沓座、躯体、主桁、対傾構等、様々な部材が写りこんでいる。学習時において、これらの他部材の干渉の除外と、学習時の計算負荷の抑制を目的として、オリジナルの損傷画像から支承部分のみを抽出した。

(3) エッジ画像の作成

GAN の学習は鋼製支承の画像に加え、特徴画像（鋼製支承の特徴部分のみを残した画像）が必要となる。本研究において、後者は支承画像からエッジのみを抽出した画像とした。エッジ画像の作成は、(2)で作成した支承部分のみを切り出した画像から、画像処理を用いて、支承の輪郭部のみを抽出することで生成した。

2. 3. 機械学習

GAN への学習データは、支承画像と合わせて支承の特徴画像であるエッジ画像をペアで用意し、入力する。学習用に使用した鋼製支承の画像枚数は 972 枚である。学習を終えたモデルは、任意の支承のエッジ画像を入力すると、学習結果を基にした疑似損傷画像を生成する。図-3 に GAN の学習および画像出力イメージを示す。

2. 4. 生成画像の精度確認

学習を終えた GAN によって生成した支承損傷画像の一部を図-4 に示す。生成に用いた画像は、学習と重複していない 197 枚を使用した。図中の(a)(b)はオリジナルおよびエッジ画像であり、(c)は GAN が生成した支承画像である。図より、学習データの画像と類似しつつも、印象の異なる支承画像を生成していることが確認できる。本画像を CNN に投入することにより、支承の画像判定の精度の向上が期待できる。

3. まとめ

本研究では、GAN を用いた損傷画像の生成について検証した。得られた知見を以下に述べる。鋼製支承画像及び鋼製支承のエッジ画像を用いて GAN を学習することにより、CNN の学習に活用が期待できる疑似損傷画像を作成することができた。今後は、CNN にこれらの画像を入力し、学習精度が改善するか検証する予定である。

なお、本研究で用いたデータは新潟県建設技術センターを通し、新潟県市町村から提供されたものです。ここに謝意を表します。

参考文献

- 1)新潟県土木部道路管理課，「新潟県定期点検要領[標準点検編]」(2014)。
- 2)国土交通省，「デジタル写真管理基準」(2008)。




図-3 GAN の学習・生成イメージ



(a) オリジナル (b) エッジ画像 (c) 生成画像

図-4 GAN 学習画像と生成画像