

## Conditional GAN を用いた生成型学習法によるひび割れ検出 Crack detection by generative learning using Conditional GAN

原口 俊樹<sup>†</sup> 黒木 修隆<sup>†</sup> 廣瀬 哲也<sup>‡</sup> 沼 昌宏<sup>†</sup>  
Toshiki Haraguchi<sup>†</sup> Nobutaka Kuroki<sup>†</sup> Tetsuya Hirose<sup>‡</sup> Masahiro Numa<sup>†</sup>

### 1. はじめに

近年、高度経済成長期に建造されたインフラの老朽化が問題となっている。そこで、これらの点検作業を AI で自動化する取り組みが盛んに行われている。しかし、AI の訓練には膨大な学習用サンプルが必要となる。これらを人手で収集し、アノテーション（教師ラベルを付与する作業）を行うのは容易ではない。本稿では、CNN によるひび割れの自動検出を目的とし、学習用サンプルを Conditional GAN によって大量生成する手法を提案する。

### 2. 従来手法

#### 2.1 概要

ひび割れの学習用画像を作成する際に最も時間がかかる作業は、ひび割れの撮影ではなくアノテーション作業である。実写のひび割れに対してマウスを用いてピクセル単位でトレースすることは、膨大な労力を必要とする。そこで我々は従来よりひび割れ画像を CG で生成する手法を採用している[1]。図 1 に従来手法を示す。背景にはアスファルトやコンクリート等の実写を用いているが、ひび割れ自体は CG である。これにより、数十枚の背景画像から数万枚の学習用画像を生成することに成功した。

#### 2.2 従来手法の問題点

従来手法では図 2 のように若干の不自然さが残ることが問題となっていた。この原因の一つは、ひび割れ自体に陰影がないことである。実際には背景とひび割れの陰影が無相関とは考えにくい。そこで本稿ではよりリアルな CG 合成を目的とし、Conditional GAN を用いたひび割れと背景

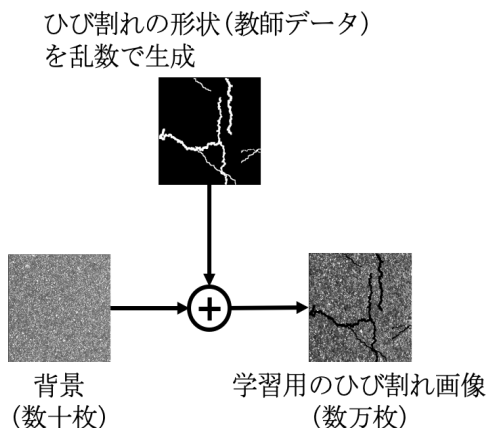


図 1 従来手法のひび割れ画像生成工程




図 2 従来手法で生成された画像

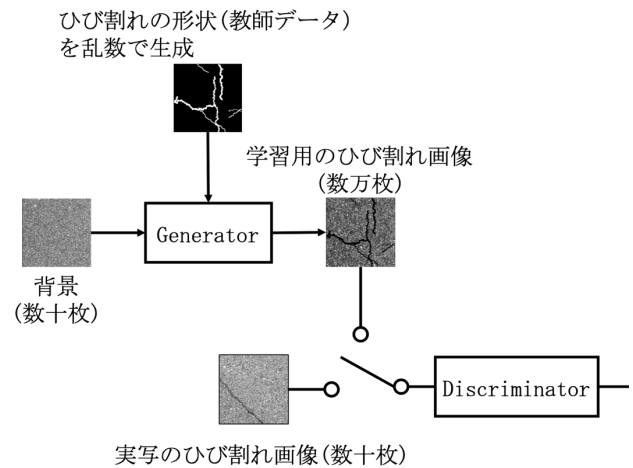


図 3 提案手法のひび割れ画像生成工程

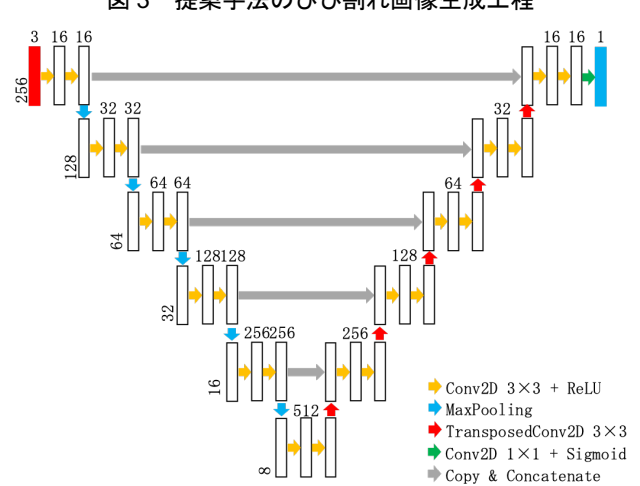


図 4 U-Net の構成図

の合成方法を提案する。

### 3. 提案手法

#### 3.1 ひび割れ画像の生成工程

図 3 に提案手法を示す。提案手法はひび割れと背景を合成するだけでなく、それと実写との差異を Discriminator で評価する点が従来手法と異なる。Discriminator は CG と実写とを判別できるように学習を進める一方で、Generator は

<sup>†</sup> 神戸大学大学院工学研究科

Graduate School of Engineering, Kobe University

<sup>‡</sup> 大阪大学大学院工学研究科

Graduate School of Engineering, Osaka University

表 1 生成されたひび割れのリアリティーの評価

被験者	TP	TN	FP	FN	正答率 [%]
A	8	8	2	2	80
B	5	8	2	5	65
C	8	8	2	2	80
D	11	5	4	0	80
E	9	7	3	1	80



図 5 提案手法によって生成された画像

表 2 ひび割れ検出精度の評価

手法	適合率	再現率	F 値
従来手法	0.091	0.904	0.163
提案手法	0.471	0.820	0.583

両者が判別できないように学習を進める。その結果、Generator は実写さながらの陰影を持つひび割れを生成可能になる。なお、ひび割れの形状については GAN の外部で生成する。その理由は、GAN による生成画像とは別に、ひび割れの位置を示す教師データを保存しておかなければならないからである。提案手法の特徴は、実写のひび割れに対して全くアノテーションを行わないにもかかわらず、実写さながらのひび割れ画像、およびその教師データを大量に得られることである。

### 3.2 ひび割れ検出 CNN

ひび割れ検出 CNN には U-Net を利用する。図 4 に U-Net の構造を示す。入力カラー画像とする。また入力サイズは  $256 \times 256$  pixel とする。本手法では U-Net の UpSampling 層を TransposedConv2D 層に置き換える。このようにすることで、より精度の高いセグメンテーションが期待できる。

## 4. 評価実験

実験では、生成されたひび割れ画像に対するリアリティーの評価および実際のひび割れ画像に対する検出精度評価を行う。

### 4.1 生成されたひび割れ画像の主観評価

図 5 に提案手法によって生成された画像を示す。これらの画像では、ひび割れの周囲に陰影が生成されていることを確認した。また従来手法では表現できなかったひび割れのくぼみなどを自動で生成できていることを確認した。

続いて、表 1 に被験者 5 人に対して実際のひび割れ画像と生成したひび割れ画像を選別評価させた結果を示す。ここで TP および TN は、本物を本物、CG を CG と正しく区別できた数を表している。一方、FP および FN は、本物と CG を区別できなかった数を表している。このように合計 100 サンプルのうち 23 サンプルについて、被験者らは本物と CG との区別ができなかった。

### 4.2 実写のひび割れに対する検出精度

提案手法によって 1 万枚のひび割れ画像を生成するとと




図 6 検出結果の主観的評価

— 検出 — 誤検出 — 未検出

図 6 検出結果の主観的評価

もに、それらをセグメンテーションするような U-Net の学習を行った。表 2 に 10 枚の実写のひび割れ画像に対する検出精度の平均値を示す。適合率では提案手法が従来手法より 0.38 pt 高く、再現率では従来手法が 0.084 pt 高い。F 値では提案手法が 0.42 pt 高い結果となった。これらの結果から、提案手法は誤検出を抑える方向に働くことがわかる。

### 4.3 ひび割れ検出の主観的評価

図 6 に従来手法および提案手法によるひび割れ検出結果を示す。従来手法ではひび割れの検出率は高いが、同時に多くの誤検出が発生していることが確認できる。一方、提案手法では従来手法で生じていた誤検出を大幅に削減できた。このように、提案手法は実際のひび割れに対しても大きな効果を発揮することを確認した。

## 5. まとめ

本研究では Conditional GAN を用いた生成型学習法によるひび割れ検出システムの構築を行った。提案手法によって生成された画像を用いて U-Net の学習を行った所、F 値が 0.583 と従来手法を 0.42 pt 上回る高い検出精度が得られた。今後の展望として様々な天候や日照変化をシミュレートすることで、よりリアルなデータセットを生成し、実写のノイズに対するロバスト性を改善することが挙げられる。

### 参考文献

- [1] 原口 俊樹, 黒木 修隆, 廣瀬 哲也, 沼 昌宏, “畳み込みニューラルネットワークを用いたアスファルトのひび割れ検出と画像のスケール判断”, 電気関係学会関西連合大会 2019