

畳み込みニューラルネットワークと生成型学習法を用いた コンクリートのひび割れ抽出

Detection of Concrete Cracks with Convolutional Neural Network and Generative Learning

岡田 大幹[†] 黒木 修隆[†] 廣瀬 哲也[†] 沼 昌宏[†]
Taiki Okada Nobutaka Kuroki Tetsuya Hirose Masahiro Numa

1. はじめに

社会インフラの老朽化の自動検出に関する技術の開発が求められている。中でも、画像処理を用いた技術に注目が集まっている。本研究では、コンクリートの画像から畳み込みニューラルネットワーク (CNN) を用いてひび割れ抽出を行ったので報告する。

2. 関連技術 [1]

2.1 適応的二値化

入力画像から作成されたグレースケール画像に対して、グレースケール画像を X ，出力画像を G ，注目画素を (x, y) とすると、

$$G(x, y) = \begin{cases} 1 & \text{if } X(x, y) > Th(x, y) \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

にしたがって二値化を行う。式 (1) で用いられている閾値 $Th(x, y)$ はブロックサイズ $S \times S$ の近傍領域に対して加重平均をとることにより

$$Th(x, y) = \frac{1}{S^2} \sum_{i=-\frac{S}{2}}^{\frac{S}{2}} \sum_{j=-\frac{S}{2}}^{\frac{S}{2}} X(x+i, y+j) \quad (2)$$

のように決定される。閾値が近傍領域で適応的に決定されるため、近傍領域内で画素値が低くなるひび割れを効果的に抽出可能である。

2.2 直線状ノイズ除去

コンクリートの接合部などの人工的な幾何学模様や直線状ノイズを除去するにはハフ変換が有効である。ハフ変換は特徴抽出手法のひとつであり、直線や円の検出に用いられる。これにより、得られた直線領域 H を

$$H = \text{Hough}(G) \quad (3)$$

と定義する。 H は二値画像である。この直線領域 H を G から除去することにより

$$J = G \cap \bar{H} \quad (4)$$

のように画像 J を得る。

2.3 粒状ノイズ除去

2.2 節で出力された画像 J に対して粒状のノイズを除去するため、メディアンフィルタが有効である。この処理を

$$K = \text{Median}(J) \quad (5)$$

と定義する。

3. CNN を用いたひび割れ抽出手法

3.1 ひび割れ抽出の流れ

提案するひび割れ抽出の流れを図 1 に示す。適応的二値化、直線状ノイズ除去、および粒状ノイズ除去までは従来技術を用いる。それらの前処理を終えた画像を CNN に入力することで、ひび割れのみを描画した出力画像を得る。CNN の構成を図 2 に示す。前処理を終えた画像 K をあらかじめ生成型学習法で構築した CNN に入力する。1 層目の特徴マップ $F_1(K)$ は

$$F_1(K) = \max(\mathbf{0}, K * W_1 + B_1) \quad (6)$$

のように求められる。ここで、 W_1 はフィルタ、 B_1 はバイアスである。

次に第 2 層の特徴マップ $F_2(K)$ は、

$$F_2(K) = \max(\mathbf{0}, F_1(K) * W_2 + B_2) \quad (7)$$

のように求める。これらのパラメータの意味は式 (6) と同様である。

同様に、第 3 層は第 2 層で抽出した特徴をもとに、

$$F_3(K) = F_2(K) * W_3 + B_3 \quad (8)$$

のように求める。次節からは、CNN の学習に必要なデータセットの作成方法について述べる。

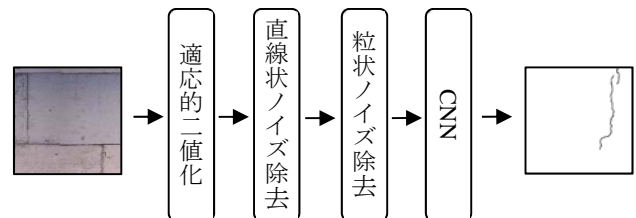


図 1 提案手法の処理の流れ

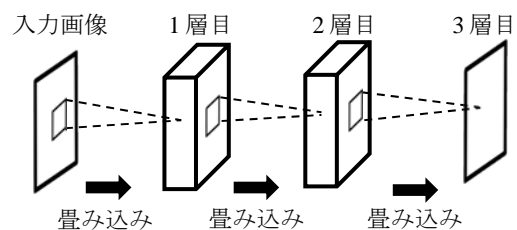


図 2 提案手法の CNN の構造

3.2 生成型学習法

CNN の学習には膨大な教師データを必要とする。限られた学習サンプルしか用意されていないデータセットの場合

[†] 神戸大学大学院工学研究科,
Graduate School of Engineering, Kobe University

は、サンプルを人工的に増やす生成型学習法が有効な手段となる。本研究ではコンクリートの画像にひび割れを自動生成し、学習サンプルとする。これにより、原理的には無限個の学習サンプルを得ることが出来るため、実データの収集コストが低減される。

図 3 に擬似的なひび割れ画像の生成の流れを示す。まず、背景画像としてひび割れの無い実際の壁を撮影したものを用意する。そこへ、疑似的に壁のつなぎ目やひび割れを表現した線を描画する。点 $P_0(x_0, y_0) \sim P_k(x_k, y_k)$ までのひび割れがある時、次の点 $P_{k+1}(x_{k+1}, y_{k+1})$ にひび割れが走る確率は、

$$(y_k - y_{k+1} + R)^2 + (x_k - x_{k+1})^2 \leq R^2 \quad (9)$$

を満たす半径 R の円内に均等に分布するものとする。これにより、ひび割れの方向に規則性が生じないようにし、かつ全体的には上から下へとひび割れが走るように描画することが出来る。さらに、ガウシアンノイズを加えることで、学習する際にノイズに対して頑健にする。

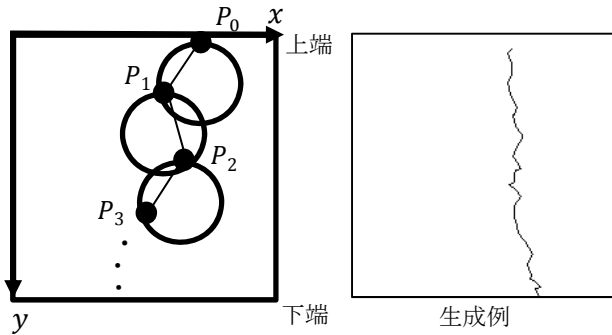


図 3 擬似ひび割れ画像の生成アルゴリズム

4. 評価実験と考察

提案手法を用いてコンクリートのひび割れ抽出を行った。また、CNN の学習時に使うサンプル数を増やしながら、生成型学習法の有用性を確認した。CNN のフィルタサイズは 1 層目から順に 5-5-3、特徴マップ数は 16-8-1 とした。また、学習時の学習係数は 0.0001、学習回数は 100 万回とした。図 4 にひび割れが写った評価用画像 10 枚を示す。評価項目は適合率、再現率、F 値とする。

提案手法の学習サンプル数による検出結果を表 1 に示す。表 1 から、学習枚数が多いほど適合率、再現率、F 値が高くなる事が分かる。したがって、生成した学習サンプルが CNN の学習に有効であるといえる。出力結果の一例を図 5 に示す。壁の汚れなどのノイズを完全には除去しきれないが、ひび割れを概ね出力できていることが確認できる。

5. まとめ

本研究では、高精度なコンクリートのひび割れ抽出システムの作成を目的に、CNN と生成型学習法を用いたひび割れ抽出手法を提案した。評価実験の結果、CNN の学習において生成型学習法が有効であることを確認した。今後は、実際のひび割れをより忠実に再現したパラメータの設定を行う予定である。




図 4 評価用画像

表 1 学習サンプル数毎の比較 (平均値)

学習枚数 [枚]	適合率 [%]	再現率 [%]	F 値 [%]
100	34.65	51.60	39.32
500	36.02	58.32	42.39
1000	38.44	61.33	44.68
CNN 無しの場合	30.50	82.68	39.23

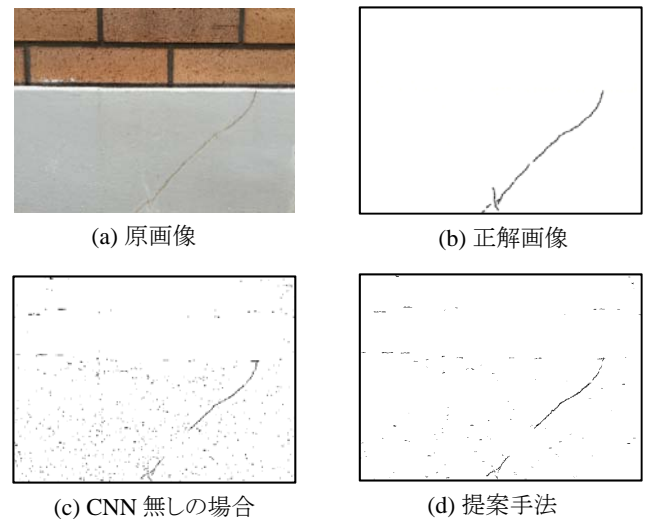


図 5 実際のひび割れ画像に対する抽出結果

参考文献

[1] R. Hanaki, N. Kuroki, T. Hirose, and M. Numa, "Crack extraction from noisy images with fractal dimension analysis," 2016 RISP International Workshop on Nonlinear Circuits, Communications and Signal Processing (NCSP 2016), 8PM1-1-5.