

## クラックの幅に着目した疑似画像データを用いた CNN によるクラック検出精度の評価 Evaluation of Crack Detection Accuracy for CNN with Pseudo Image Data by Considering Crack Width

齋藤 実樹生<sup>†</sup>      太田 修平<sup>‡</sup>      石井 信明<sup>‡</sup>  
Mikio Saito      Shuhei Ota      Nobuaki Ishii

### 1. 研究背景

特殊建築物、橋、トンネル、ダムなどの多くのコンクリート構造物には、定期的な点検が必要である。

点検の現場では、コンクリートの耐久性に関わる幅 0.05mm 以上のクラックと、修復の目安とされている幅 0.2mm 以上のクラック検出作業の多くを目視で行っており、クラック検出に長時間を要している。また、検査員の熟練度によって、クラック検出の精度や作業時間などが変わるため、検出精度や点検費用に課題がある。

クラック検出には多くの手法があるが、深層学習の一つである、畳み込みニューラルネットワーク(CNN)によるクラック検出が有効とされる[1]。CNN は画像認識の技術であり、壁面画像中のクラック箇所を検出できる。

CNN によるクラック検出の精度を向上するためには、多くの学習データを用意する必要がある。しかし、希少なクラックや新しい構造物のクラックは多くないことから画像が少なく、学習データの生成が困難という問題がある。

### 2. 研究目的

本報では、本物のクラック画像であるオープンデータセットで学習した場合と同等以上の検出結果を得られる疑似クラック画像の生成方法と、クラック検出方法の提案を目的とする。新規性は、簡易的に疑似クラック画像を生成する方法を提案することである。

### 3. 先行研究

齋藤ら[2]は、疑似クラック画像を用いた属性毎のサブデータセットのクラック検出で、クラックの向きと位置を考慮したが、クラックの太さを考慮していない。

また、Talukder[3]が実験を行ったサブデータセットは、影のある画像とない画像でデータセットを作成したが、クラックの特徴、および属性を考慮していない。

### 4. 提案手法

疑似クラック画像の生成は、クラックのない一般のコンクリート壁の画像の上に、画像編集ソフトを用いてクラックを生成する。生成手法は2つある。1つは、クラックのある画像からクラックの部分を切り取り、切り取ったクラックのみの画像をクラックのない一般のコンクリート壁の画像の上に重ね合わせて画像を生成する方法。2つ目は、クラックのない一般のコンクリート壁の画像の上からクラックの属性である波線や枝分かれしている画像を、描画ソフトを用いて手作業で描画して生成する。

また、本報ではサブデータセットを用いてクラックの検出を行う。サブデータセットは、疑似クラック画像からク

ラック検出の精度が変化すると考えられるクラックの属性毎に分類した画像で作成する。

最後に、サブデータセットごとに得られる検出結果を1つにまとめる。クラックありの判断は、サブデータセットから得られた結果に1つでもクラックありと検出されたテストデータはクラックありと判別する。クラックなしはサブデータセットから得られる結果がすべてクラックなしと検出されたテストデータのみをクラックなしと判別する。

### 5. 数値実験

#### 5.1. 実験の設定

本実験では、MATLAB を用いて CNN を実装した。畳み込み層、プーリング層、出力層の8層からなるCNNを使用し、エポック数を10、バッチサイズは32とした。実験と学習データの概要を表1に示す。

表1 実験と学習データの概要

実験	学習データ			
	クラックあり	枚数(枚)	クラックなし	枚数(枚)
Exp.1	METU	19,950	METU	19,950
Exp.2-1	1~15px	50	テストデータに対応した建物の背景を使ったクラックのない画像	50
Exp.2-2	1~15px 縦向き	50		50
Exp.2-3	1~15px 横向き	50		50
Exp.2-4	16~30px	50		50
Exp.2-5	16~30px 縦向き	50		50
Exp.2-6	16~30px 横向き	50		50
Exp.2-7	31~45px	50		50
Exp.2-8	31~45px 縦向き	50		50
Exp.2-9	31~45px 横向き	50		50

学習データでは、本物のクラック画像にオープンデータセットの Middle East Technical University(METU)の画像を使用する。疑似クラック画像は、背景に神奈川大学の5号館と23号館の画像を使用し、クラック部分は神奈川大学23号館、Utah State University[4]、METU[5]の画像を使用する。

クラックの幅は1~15px、16~30px、31~45pxの3種類とクラックの向きは縦向き、横向きの2種類、向きに関係なく生成した疑似クラック画像のサブデータセットを作成する。

本報で使用する学習データとテストデータの画像サイズは、それぞれ縦227px、横227pxである。クラックの幅が15pxごとのサブデータセットを作成するため、クラックの幅は1~15px、16~30px、31~45pxの幅で疑似クラック画像を生成する。サブデータセットの1つは、指定の幅に収ま

<sup>†</sup> 神奈川大学大学院工学研究科

Graduate School of Engineering, Kanagawa University

<sup>‡</sup> 神奈川大学工学部経営工学科

Faculty of Engineering, Kanagawa University

るクラックでクラックの向きに関係なく生成した疑似クラック画像を集めたデータセット、他の 2 つは、指定の幅に収まるクラックで縦向きの疑似クラック画像と横向きの疑似クラック画像を集めたデータセットである。

テストデータには、神奈川大学の 5 号館と 23 号館のクラック画像を使用している。神奈川大学 5 号館はクラックの幅が 4~26px で、クラックあり画像 3,680 枚、クラックなし画像 3,680 枚を使用し、23 号館はクラックの幅が 6~17px で、クラックあり画像 853 枚、クラックなし画像 853 枚を使用する。

## 5.2. 評価指標

実験では、真陽性(TP)、真陰性(TN)、偽陽性(FP)、偽陰性(FN)の 4 種類のデータを得る。これらを用いてクラック画像をどのくらい正しく検出できたかを表す指標の Recall[6]と、検出結果がどれくらいテストデータの結果と一致しているかを表す指標の Accuracy[6]の 2 つを使って検出結果を比較する。

## 5.3. 結果

神奈川大学 5 号館と 23 号館をテストデータにした結果を表 3 に示す。

表 3 神奈川大学 5 号館のクラック検出結果

テストデータ	実験	Recall	Accuracy
5 号館	Exp.1	0.846	0.914
	Exp.2-1	0.834	0.901
	Exp.2-2	0.802	0.883
	Exp.2-3	0.858	0.917
	Exp.2-4	0.817	0.891
	Exp.2-5	0.770	0.865
	Exp.2-6	0.838	0.906
	Exp.2-7	0.707	0.841
	Exp.2-8	0.701	0.838
23 号館	Exp.1	0.867	0.918
	Exp.2-1	0.843	0.917
	Exp.2-2	0.859	0.926
	Exp.2-3	0.785	0.887
	Exp.2-4	0.732	0.863
	Exp.2-5	0.737	0.863
	Exp.2-6	0.704	0.844
	Exp.2-7	0.606	0.800
	Exp.2-8	0.641	0.818
Exp.2-9	0.593	0.792	

表 3 より、学習データのクラックの幅が細いほど精度が高くなる。また、疑似クラック画像を用いた実験結果で、クラックの幅と向きがテストデータと合うサブデータセットの検出結果は、Exp.1 のオープンデータセットで学習した検出結果より高い精度が得られた。

神奈川大学 5 号館は横向きのクラックが多いため、学習データが横向きのデータセット、向きが関係ないデータセット、縦向きのデータセットの順に精度が高い。23 号館は縦向きのクラック画像が多いため、学習データが縦向きのデータセット、向きが関係ないデータセット、横向きのデータセットの順で精度が高い。

## 5.4. 考察

学習データのクラックの幅が細いほど Recall、Accuracy の指標でともに高い評価を得られる。テストデータである 5 号館はクラックの幅は 4~26px であるため、学習データのクラックの幅が 1~15px、16~30px の疑似クラック画像のクラックの幅と差が小さいため、テストデータとクラックの向きが異なる Exp.2-5 を除く Exp.2-1 から Exp.2-6 までは同様の評価である。また、テストデータである 23 号館はクラックの幅が 6~17px であるため、Exp.2-1 から Exp.2-3 の学習データのクラックの幅が 1~15px の疑似クラック画像で検出した方が評価が高い。そのため、テストデータと学習データのクラックの幅の差は、小さい方が評価が高くなると考えられる。しかし、Accuracy は Recall ほど実験ごとに差が見られない。テストデータと学習データのクラックの幅の差が大きくなると TP は減るが、TN が増えているため、大きな差にならない。TN が増える理由としては、テストデータのクラックの幅に合わない学習データを使うと、クラックなしと判定する割合が増えるからだと考えられる。そのため、クラックの検出においてはクラックの幅を合わせることが重要である。

また、クラックの向きがテストデータと合うことで Recall と Accuracy の評価が高くなることから、その他の属性もテストデータと近い属性を学習データに与えると評価が高くなると考えられる。

## 6. まとめと今後の課題

神奈川大学の 5 号館と 23 号館を例に、クラックの幅に着目して、オープンデータセットを学習した場合と疑似クラック画像を学習した場合でクラック検出を行った。その結果、学習データのクラックの幅は、テストデータの幅に近い方が検出結果が良くなることがわかった。また、オープンデータセットで学習した検出結果より、疑似クラック画像で学習した検出結果の方が良くなる場合があることがわかった。

今後は、サブデータセットを増やすために、クラックの枝分かれの属性などを増やす。また、本報では疑似クラック画像の背景はテストデータの背景と似た背景で生成したため、異なる場合の検出結果を収集する必要がある。

### 参考文献

- [1] Cha, Y. J., Choi, W., and Büyükoztürk, O.: "Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks," *Computer-Aided Civil and Infrastructure Engineering*, Vol. 32, No. 5, pp. 361-378 (2017)
- [2] 齋藤 実樹生, 太田 修平, 石井 信明, "CNN による疑似クラックを用いたクラック検出精度向上手法の検討," 日本設備管理学会 2024 年度 春季研究発表会, A2-4 (2024)
- [3] Talukder, M. H., Ota, S., Takanokura, M. and Ishii, N.: "Performance Evaluation of CNN-based Crack Detection using Training Datasets Generated by the Crack Cropping Method from Each Maintenance Target", *Journal of the Society of Plant Engineers Japan*, Vol. 34, No. 3, pp. 52-59 (2022)
- [4] Özgenel, Ç. F. and Sorguç, A. G.: Performance Comparison of Convolutional Neural Networks on Crack Detection in Building, "Proceedings of the 35th ISARC", pp. 693-700(2018)
- [5] UtahState University UNIVERSITY LIBRARIES, [https://digitalcommons.usu.edu/all\\_datasets/48/](https://digitalcommons.usu.edu/all_datasets/48/)(参照:2024/04/21)
- [6] 原田 達也, "画像認識," 講談社, (2017)