

画像認識によるガードレールの腐食検出手法の検討

NTT アクセスサービスシステム研究所 正会員 ○伊藤 航, 内堀 大輔
NTT アクセスサービスシステム研究所 非会員 櫻田 洋介, 荒武 淳

1. はじめに

社会インフラの維持管理では、老朽化設備の増加や技術者の減少等が喫緊の問題になっている。この問題に対し、画像認識や劣化予測等を可能とする AI を導入し、効率化を図る検討が進められている。

インフラ点検業務では、現在点検員による目視が主な方法であるため、目視に代わる手段として、画像認識による劣化検出技術が広く検討されている。既往研究¹⁾ではコンクリートに発生したクラックの検出手法を提案している。画像中の微小なクラックを深層学習手法によって高精度に検出しているが、取得画像にコンクリート面のみが写っていることが前提となっていて、カメラ画角内にコンクリート面のみを収めるといった撮影方法の制約がある。実際の社会インフラの点検を画像から効率的に実施しようとする、取得画像から検査対象の物体を抽出する必要がある。

本検討では、車両から沿道を撮影した画像を用いて、撮影画像中に写るガードレールを認識し、ガードレールに発生した腐食を検出する手法を検討する。検査対象となる特定の物体にフォーカスした撮影画像でなくとも、対象物の劣化を検出可能か検証する。

2. 提案手法

提案するモデルは、既往研究²⁾における手法を活用した。本手法では、画像全体から腐食画素を検出する判定器と設備領域の画素を検出する判定器をそれぞれ構築し、両者の論理積を取ることで検査対象となる設備の腐食画素のみを検出する。腐食の画素領域検出には Olaf³⁾が提案する深層学習手法によるセマンティックセグメンテーションモデルをベースに、損失関数を AUC maximization⁴⁾ (AUC-Max) に改良した。この損失関数は、対象となる物体 (腐食) の検出率の向上を優先した学習をモデルが行う特徴がある。腐食検出には、取得画像を正方形の矩形領域に分割し、各分割画像で腐食検出を実施する。分割画像における腐食検出は同様に Olaf

ら³⁾の提案モデルをベースにし、損失関数を Binary cross entropy (BCE) と Tversky⁵⁾の2種類で検出器を構築し、比較を行うこととした。設備の検出には、設備の全体の形状を保持することが重要であると考えたため、腐食検出で実施したような取得画像の分割は実施しない。

3. データセットと検証条件

画像データは車両に搭載したデジタルカメラにより撮影した 4750 枚のカラー画像 (5120 px. × 5120 px.) を用いる。カラー画像に対して、ガードレールが写っている画素領域とガードレールの腐食が写っている画素領域が特定可能な教師データを作成した。4750 枚のカラー画像においてガードレールの腐食が確認できた画像は 3078 枚であった。3078 枚の各画像を 256 px. × 256 px. の矩形に分割した画像を生成した。

検証条件を以下に示す。腐食検出の学習にはカラー画像 3078 枚から生成した分割画像のうち腐食の画素領域が含まれる分割画像を用いた。設備検出は、カラー画像 4750 枚を計算機の制約により解像度を 512 px. × 512 px. にリサイズし検証した。学習に 4500 枚を用いることとした。腐食の検出、設備の検出ともに評価はカラー画像 250 枚で実施した。また、学習回数は腐食検出では 100 回、設備検出では 200 回とした。学習率は 1×10^{-4} から始め、50 回の学習で損失値の低下が見られなかった場合、学習率を 10^{-1} 倍する手法を採用した。評価には表-1 の混同行列に基づき、再現率 (Recall)、適合率 (Precision)、F-score の評価指標を用いた。これらは式 (1), (2), (3) で表される。

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$F - score = \frac{2Recall \cdot Precision}{Recall + Precision} \quad (3)$$

キーワード：腐食, 点検, ガードレール, 画像認識, 深層学習, セマンティックセグメンテーション

〒305-0805 茨城県つくば市花畑 1-7-1 NTT アクセスサービスシステム研究所 Tel:029-868-6324

表-1 混同行列

| Actual(Classess) | Predicted(Clusters) | |
|------------------|---------------------|----------|
| | Positive | Negative |
| Positive | TP | FN |
| Negative | FP | TN |

表-1 の混同行列は、腐食画素及び設備画素を Positive、非腐食画素及び非設備画素を Negative として定義した。

4. 検証結果と考察

検証結果を表-2 に示す。表-2 は評価画像 250 枚の平均スコアを示している。またそれぞれのモデルによる検出例を図-2 に示す。(a)は撮影したカラー画像、(b)は腐食検出モデルのみの結果、(c)は設備検出モデルのみの結果、(d)は提案モデルの検出結果である。まず腐食のみの検出について Recall が 0.939 と十分高い一方、Precision が 0.129 と低い結果となった。この理由は、学習時の損失関数に AUC-Max を用いたため、TP が向上した一方で、FP が多く発生したためと考えられる。図-2(b)で右上の岩の部分に FP が発生していることが確認できる。次に設備のみ検出では、BCE を使用したモデルの F-score は 0.948、Tversky を使用したモデルの F-score は 0.953 であった。よってスコアの高かった Tversky で学習した検出器を提案モデルに採用することとした。提案モデルでは Recall が 0.904、Precision が 0.632、F-score が 0.743 という結果となった。AUC-Max を用いた腐食検出モデルと比較し Recall が 0.035 とわずかに低下したものの、Precision が 0.503 と大きく増加した。図-2(b)の右上の岩の部分に過検出された腐食領域は図-2(c)が示す通り設備として検出されていないため、図-2(d)では消えていることが確認できる。この結果から、提案モデルは腐食のみの検出と比較し、腐食の TP をほぼ維持しつつ FP の抑制が可能であると考えられる。

5. まとめ

本検討では、特定の物体にフォーカスした撮影画像でなくとも、対象物の劣化を高精度に検出できるか検証した。提案モデルはガードレールの設備の画素領域を認識し腐食の画素領域を 9 割以上検出できるため、実地で十分に活用できると考えられる。

表-2 評価結果

| | 腐食検出 | 設備検出 | | 提案手法 |
|-----------|-------|-------|---------|-------|
| | | BCE | Tversky | |
| recall | 0.939 | 0.921 | 0.977 | 0.904 |
| Precision | 0.129 | 0.977 | 0.930 | 0.632 |
| F-score | 0.227 | 0.948 | 0.953 | 0.743 |

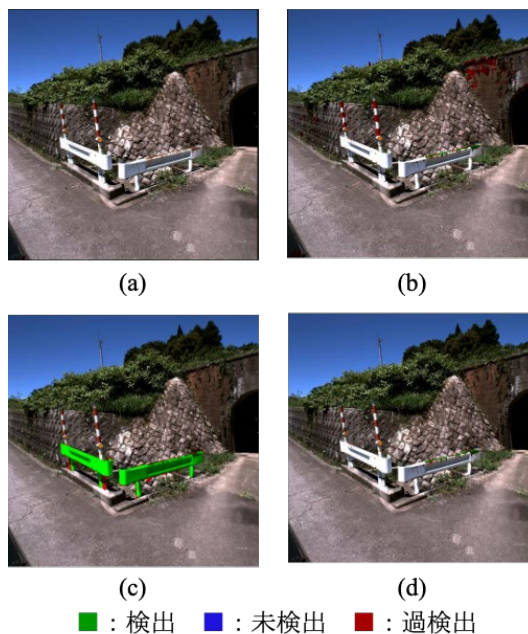


図-2 検出例

(a) : 撮影画像, (b) : 腐食検出モデル,
(c) : 設備検出モデル, (d) : 提案モデル

参考文献

- 1) Mohamed Alipour, Devin K Harris, and Gregory R miller S. M. S. et al.: Robust Pixel-Level Crack Detection Using Convolutional Neural Networks, Journal of Computing in Civil Engineering, 33(6), 04019040, 2019.
- 2) 内堀ら: 画像認識による鋼材の腐食領域の検出手法, 令和4年度土木学会全国大会(投稿中).
- 3) Olaf Ronneberger, Philipp Fischer, and Thomas Brox: U-net: Convolutional networks for biomedical image segmentation, In MIC- CAI, p.234-241, Springer, 2015.
- 4) Hanley, J. A., and B. J. McNeil: The Meaning and Use of the Area Under a Receiver Operating Characteristic (ROC) Curve, Preprint, Radiolog, Vol.143, No.1, p.29-36, 1982.
- 5) Seyed, S. M. S. et al.: Tversky loss function for image segmentation using 3D fully convolutional deep networks, Preprint, submitted 17 Jun 2017.