

深層学習を用いた橋梁添架設備の個別領域認識手法の検討

NTT アクセスサービスシステム研究所 正会員 ○濱野 勇臣, 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

日本電信電話株式会社 (NTT) は通信サービスを提供するため、全国約4万橋に通信用管路を敷設している。

図-1はNTTが保有する橋梁添架設備であり、多くの場合、複数本の管路およびそれを支持する添架装置で構成される。これらの設備を維持するために定期的に点検を行っている。しかし、点検作業者が減少する中、作業効率化が喫緊の課題となっている。

既往研究では、深層学習を用いて点検画像から橋梁添架設備が写る領域を認識し、認識領域内で生じた腐食を検出するアルゴリズムを構築した。このアルゴリズムにより、橋梁添架設備における腐食有無の判定作業を自動化する手法が提案されている¹⁾。この手法は腐食の有無を判定する問題には十分有効であるが、橋梁添架設備の構成部材ごとに認識することは考慮されていないため、橋梁添架設備の各構成部材個別の腐食面積率を得ることは適用できない課題がある。各構成部材個別の腐食率を知るためには、事前に橋梁添架設備を構成する各部材を個別かつ画素ごとに認識する必要がある。その上で腐食を検出し、各構成部材ごとの腐食面積率を算出することで、腐食の度合いの把握が可能となる。

そこで我々は、橋梁添架設備の構成部材を個別に認識する手法の検討を行ったので、その結果について報告する。

2. 橋梁添架設備の設備領域検出方法

橋梁添架設備は、添架する橋梁の形態により管路の塗装の色や添架部材の形状が異なるため、画像認識を行う場合、人手で画像特徴量を定義することが難しい。そこで、画像から自動的に特徴量を抽出し学習モデルを構築することができる深層学習を用いた。本稿では、インスタンスセグメンテーション手法の一つであるMask-R-CNN²⁾を用いた。

一般的に、Mask-R-CNNは物体検出結果として得られ

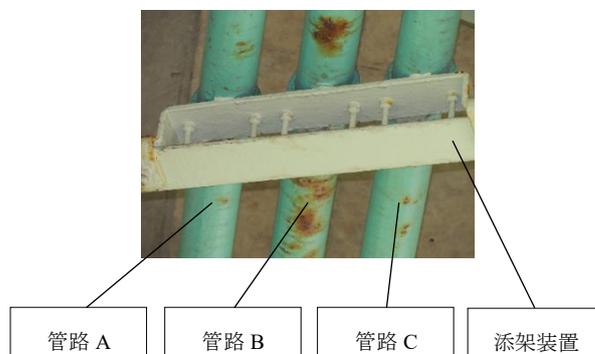


図-1 橋梁添架設備

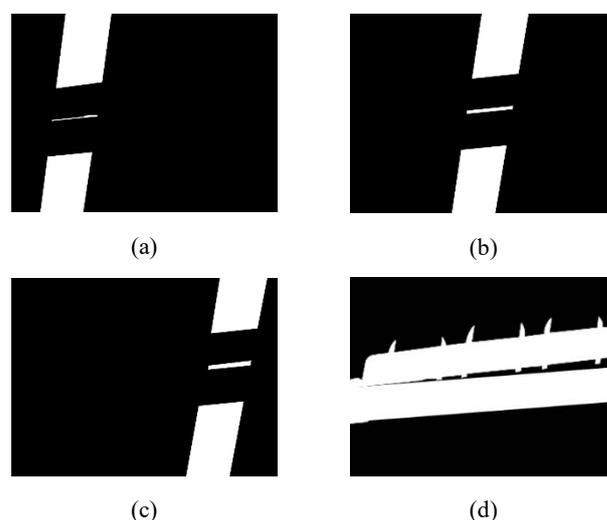


図-2 構成部材ごとの教師データ

(a) 管路 A, (b) 管路 B, (c) 管路 C, (d) 添架装置

た領域についてのみセグメンテーションを行うことができる。図-1のように複数物体が写る画像から、橋梁添架設備の構成部材ごとに領域を個別認識し、さらに、その認識領域に対してセグメンテーションすることで設備領域を個別に認識できると考えた。

3. 検証方法

設備領域の個別認識を行うための画像データは、橋梁添架設備の撮影画像100枚に対し、水平・垂直に回転および反転する処理により400枚にデータを拡張した。この400枚のうち、270枚をTraining用、30枚を

キーワード：橋梁添架, 画像処理, 深層学習, 画像セグメンテーション, 個別認識

〒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:029-868-6210

Validation 用, 100 枚を test 用としてランダムに分類して学習, 検証, 評価を実施した. また, 学習は 10,000 回実施した. アルゴリズムの評価には表-1 の混同行列に基づき, 正解率 (Accuracy), 適合率 (Precision), 再現率 (Recall) の評価指標を用いた. これらは以下の式で表される.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

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

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

設備領域の認識は, 設備画素を Positive, 非設備画素を Negative として, 表-1 の混同行列を用いて真値とモデルによる予測結果の関係性を定義した. 本検証では, 正解データは, 図-2 (a)-(d)に示すように事前に全画像に対して設備の構成部材ごとにラベル処理を施すことで, 正解を与えている.

4. 検証結果と考察

学習を行った結果を図-3 に示す. ここで縦軸に損失値, 横軸に学習回数を示している. 実線は学習データの損失, 破線は検証データの損失を示している. 図-3 から, 学習回数が大きくなるにつれて損失が低下している様子から学習が十分に進行していることを確認した.

表-2 はテスト用画像 100 枚の平均スコアを示している. $Accuracy=0.92$, $Precision=0.93$ を得た一方, $Recall=0.78$ であった. これらの結果から, 一部の画像で検出漏れがあるものの, 画像中の橋梁添架設備を個別に認識できることが分かる.

図-4 はテスト画像における検出結果の例を示している. 管路を検出した領域を赤色, 金物を検出した領域を青色でマスクしている. 図-4 (a)および(b)のように管路が画像中で垂直方向または水平方向に向いている場合には, 領域が認識できている様子を示している. 一方で図-4 (c)や(d)のように管路が斜め方向に横断する場合, 管路領域の検出漏れが発生していることを確認した. 以上のことから, 撮影画角によって検出精度が変動する可能性があると考えられる.

5. まとめ

本稿では, 橋梁添架設備の撮影画像から構成部材ごとの領域を検出する画像処理方法の検討を行った. 領域の認識には Mask R-CNN を用いて検出するアルゴリ

表-1 混同行列

Actual(Class)	Predicted(Clusters)	
	Positive	Negative
Positive	TP	FN
Negative	FP	TN

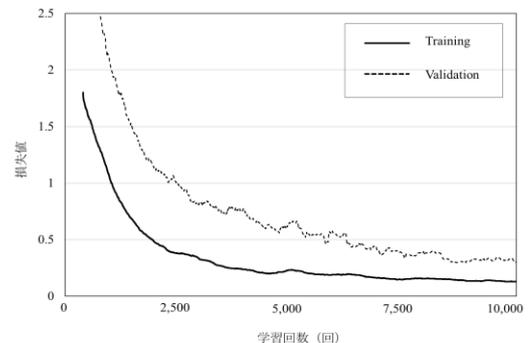


図-3 学習曲線

表-2 検出スコア

スコア (加算平均値 (100枚))	評価指標		
	Accuracy	Precision	Recall
	0.92	0.93	0.78

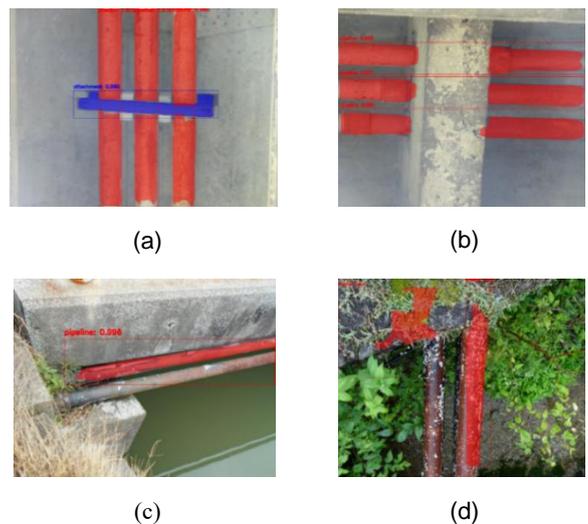


図-4 検出結果例

ズムを構築し, $Accuracy=0.92$ を得た. 一方で管路がおり角や斜め横断している画像で検出漏れが見られたことから, 撮影画角の最適化が必要と考えられる.

参考文献

- 濱野勇臣, 内堀大輔, 中川雅史, 荒武淳: 深層学習を用いた橋梁添架設備の腐食領域検出技術, 令和2年度土木学会全国大会第75回年次学術講演会, 2020, CS15-06.
- Kaiming He, Georgia Gkioxari, Piotr Dollár, Ross Girshick: "Mask R-CNN", (Submitted on 20 Mar 2017 (v1), last revised 24 Jan 2018 (this version, v3)).