

深層学習を用いた橋梁添架設備の腐食領域検出技術

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 中川 雅史, 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、主に橋梁の下部に管路が添架されている。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が、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、ドローンにより撮影した画像から橋梁の劣化を自動的に検出する技術が提案されている¹⁾。この方法は画像一面に橋梁設備のみが写っている領域に対しては十分有効であるが、風景など橋梁設備以外の領域を誤検出するため、適用には課題が残っていた。

この課題に対して、橋梁設備の撮影画像から点検対象領域を検出する画像処理方法を提案した²⁾。提案手法では、画像を一定サイズの矩形領域に分割し深層学習により矩形毎に設備領域と非設備領域の分類を行った。しかし、この手法は矩形サイズと精度の関係が示されておらず、抽出した領域から劣化を検出する手法については述べられていない。そこで、我々は設備領域の検出手法の最適化を行うとともに、点検対象領域の劣化を検出するアルゴリズムを構築した。



図-1 橋梁添架設備

2. 橋梁添架設備の腐食検出方法

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、検出対象物の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。本稿では既往研究の設備検出手法²⁾を適用し、矩形サイズと精度の関係を明らかにした。さらにその結果を用いて点検対象となる設備領域の検出を行った上で、腐食劣化の検出を行うアルゴリ

ズムを構築した結果について報告する。

設備領域の検出は、既往研究の手法²⁾を用いて設備領域と非設備領域を分類する。腐食領域の検出はセマンティックセグメンテーションの1つであるU-netを使用した。U-netはEncode部分とDecode部分で対応した特徴マップを繋ぐため、Decode時に検出した画素の位置情報を含めることができる。従って画像中に腐食か否かの二値判断ではなく、腐食領域を画素単位で検出することが可能となるため、本検証に有効と考えた。

3. 検証方法

設備領域の検出は、撮影画像を矩形に分割し、その矩形内に設備が写っているか否かの判定を行った。撮影画像サイズ(pixel)は縦480×横640に規格化した後、正方形の矩形領域に分割し、各矩形画像に一定割合以上の画素に橋梁添架設備が存在すれば、設備領域(Positive)、それ以外を非設備領域(Negative)と定義した。本検証では、撮影画像を分割する矩形サイズ(pixel)を32×32, 40×40, 80×80, 160×160の各パターンにおいて、設備・非設備を分類する際の矩形内に設備が含まれる割合(閾値)を変化させ、各パラメータにおける精度を評価した。学習回数は300回実施し、クラス分類を行うため損失関数としてbinary cross entropyを使用した。また、評価指標は表-1の混同行列からFalse Positive Rate (FPR)とTrue Positive Rate (TPR)を用いた。なお、FPRとTPRは以下の式で表される。

$$FPR = \frac{FP}{TP + FP} \quad (1)$$

$$TPR = \frac{TP}{TP + FN} \quad (2)$$

腐食領域の検出は、腐食画素をPositive、非腐食画素をNegativeとして、表-1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。学習モデルの評価には、FPRとTPRの割合を横軸と縦軸に設定した時に描かれる曲線であるROC曲線の曲線下の面積であるAUCを用いて、このAUCを評価関数とした。なお、学習回数

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, 腐食

〒305-0805 茨城県つくば市花畑1-7-1 日本電信電話株式会社アクセスサービスシステム研究所 Tel:029-868-6188

は 500 回実施した。予測値に対する閾値は (FPR, TPR) = (0, 1) と ROC 曲線のユークリッド距離を最小にする座標を算出することで決定される。

設備領域内における腐食を検出するために、上記手法から設備領域と腐食領域の画素ごとに論理積をとり、設備領域内における腐食領域の FPR と TPR を算出した。また、設備検出を行わずに腐食を検出した結果と比較を行った。

本検証では、合計 800 枚の撮影画像を用いて、700 枚を学習画像、50 枚を検証画像、50 枚をテスト画像に分類した。なお、設備検出、腐食検出それぞれ 0 から 1 の値で予測値として出力されるが、事前に全画像に対して設備領域および腐食領域の画素にそれぞれ 1 とラベル処理を施すことで、正解を与えている。

表-1. 混同行列

Classes	Predicted(Clusters)	
	Positive	Negative
Positive	TP	FN
Negative	FP	TN

4. 検証結果と考察

設備検出を行った結果を図-2 に示す。縦軸に TPR 、横軸に矩形サイズ、線種は各閾値を表している。矩形内に含まれる割合（閾値）が $th=0.3$ 以上かつ矩形サイズ 80×80 (pixel) で $TPR=0.93$ と最も高精度に検出できることが示された。図-3 に腐食検出におけるテスト画像の判定を行った ROC curve を示す。この際の AUC は 0.90 となった。図-4 はテスト画像の判定結果の一例を示している。設備検出を実施しない腐食検出結果(c)と比較して、設備検出(b)を実施した腐食検出結果(d)は過検出を抑制することができる。表-2 の(1), (2), (3)はそれぞれ図-4 (c), (d)の検出率と、設備検出を人が実施した場合の腐食検出率を示している。表-2 (2)は(3)と比較して FPR が 0.04 多く出る結果となった。この要因として、橋梁設備の鋼材と添架部材の区別が難しいことが想定される。更なる過検出率抑制には NTT 以外の設備領域も正解と定義する等、教師データ作成方法に工夫が必要と考えられる。

5. まとめ

本稿では、撮影画像から橋梁添架設備の腐食領域を検出する画像処理方法の検討を行った。設備領域の検出に画像分類、腐食検出にセグメンテーションを用いて、これらの予測値の論理積をとることで、設備領域内

での腐食を検出するアルゴリズムを構築した。直接腐食検出を行うよりも過検出を 0.10 程度抑制することができた一方、人手により設備領域を指定した腐食検出結果に対して過学習が 0.04 程度多く生じた。この理由として教師データの定義による精度依存性があると推測される。

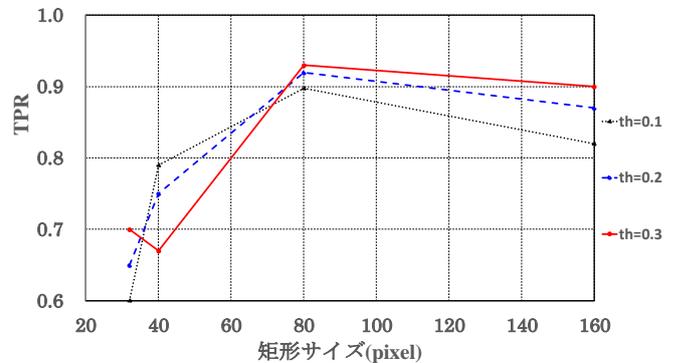


図-2. 矩形サイズと閾値の関係

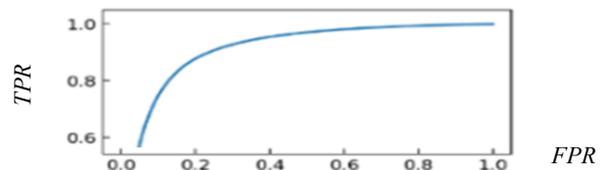


図-3. ROC 曲線

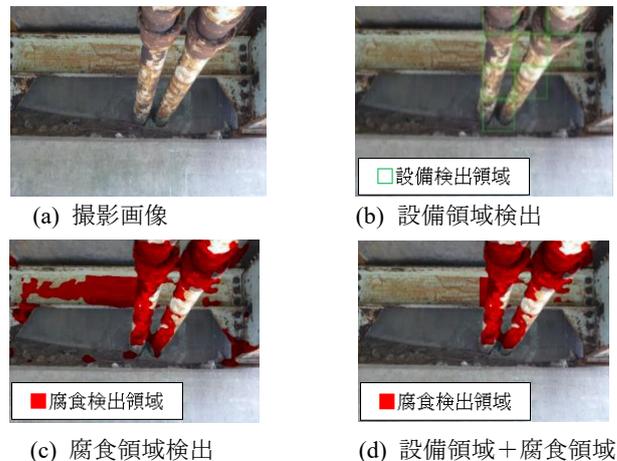


図-4. テスト画像の検出結果

表-2. 検出結果

	(1) 設備検出なし	(2) 設備検出あり(自動)	(3) 設備検出あり(人手)
TPR	0.89	0.88	0.93
FPR	0.21	0.11	0.07

参考文献

- 1) 田畑佑：UAV 撮影と深層学習を用いた橋梁損傷の自動検知に関する検証，土木学会論文，F4, Vol.74, No2, I_62-I_74, 2018.
- 2) 濱野勇臣，内堀大輔：深層学習による画像認識を用いた橋梁添架設備の領域検出技術の研究，令和元年度土木学会全国大会，2019.