

U-net を用いた深層学習による通信用マンホール内の鉄筋露出および金物腐食検出技術

NTT アクセスサービスシステム研究所 正会員 ○渡邊 一旭, 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) では、全国に通信用マンホールを約 70 万個設置しており、安全な維持管理のために定期点検を実施している。近年では、技術者の減少から点検作業の効率化が求められ、マンホールの点検診断作業を自動化する研究開発が取り組まれている。既報¹⁾では通信用マンホール内の劣化の診断技術として、セグメンテーション深層学習を用いて、点検画像内から上床版に発生する鉄筋露出およびケーブル等の収容のための金物の腐食の領域検出を行った。しかし、学習画像枚数の違いによる検出精度の評価が今後の課題となった。

セグメンテーション深層学習は、図-1 a), b) のような画像を入力し、図-1 c) 示すように画素単位に 0 から 1 の数値情報による検出結果 (1 に近いほど劣化領域である可能性が高いことを示す) が出力される。また結果を可視化するために閾値を設け、出力結果に対して図-1 d) のように二値化処理を行う。そのため、二値化処理の際に欠落する情報が存在し、ノイズのような微小な過検出領域が出力結果中に現れる。発生したノイズは、検出した領域を個々の物体としてカウントする際、検出した劣化箇所の個数を過剰にカウントする可能性がある。

そのため、本稿では既報¹⁾で対象とした通信用マンホール内の鉄筋露出および金物腐食の領域検出について、学習画像枚数を増加させた際の検出精度の影響に関する検証結果を述べる。またセグメンテーション深層学習による画素単位の領域検出結果から図-1 e) のように微小過検出領域を削除する手法についても提案する。

2. U-net による劣化の自動検出の概要

本稿で用いる深層学習のモデルは画像セグメンテーションの一手法である U-net とし、U-net 構造中の各種層の大きさをカラー画像に適用可能なように変




図-1 領域検出の出力結果と微小過検出領域の削除

更した。損失関数には Maximizing AUC を用いた。学習中の validation には、学習画像枚数の 2 割を用いることとした。学習係数は Learning Rate Range Test²⁾により各学習画像枚数に対する最適な学習係数の最大値と最小値を定め、学習中の validation 画像における損失関数 (validation loss) の値を監視し、50 epoch 以上減少がない場合に学習係数を 0.1 倍した。学習に使用する画像サイズ (pixel) はマンホール内の鉄筋露出が 480×320 、金物腐食が 512×512 の大きさの RGB 画像とした。学習は 500 epoch とし、その間の validation の損失関数が最小値をとる epoch で生成された判定器を検証に用いた。検出結果は、ROC 曲線と TP Rate 100%, FP Rate 0%の距離が最小となる距離を閾値として二値化処理を行い、2 クラス混同行列を用いて検出結果を評価した。

3. 各劣化に対する必要学習画像枚数の検討

前章で示した U-net モデルを用いて、鉄筋露出および金物腐食の点検画像における学習画像枚数毎の判定器を生成した。ここで学習画像枚数としているのは、train 画像および validation 画像を含めた画像枚数のことである。最大学習画像枚数は 900 枚の点検画像を回転および反転により 4 倍に水増し処理を行っ

キーワード 画像処理, 深層学習, 通信用マンホール, 点検, U-net

連絡先 〒300-0805 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:029-868-6245




図-2 学習画像枚数と検出精度の比較




図-3 削除する連結画素の大きさと検出精度の比較

た 3600 枚とした。生成した各判定器を用いて、学習に用いていない各 400 枚 (100 枚の画像を回転および反転により 4 倍に水増し) の test 画像における TP Rate および FP Rate を求めた。学習画像枚数と TP Rate および FP Rate の結果を図-2 に示す。鉄筋露出および金物腐食検出は、学習画像枚数を増加させることで、TP Rate が増加し、FP Rate が減少すること、学習画像枚数が一定以上になると、学習画像枚数に対する TP Rate の増加および FP Rate の減少が停滞することを確認した。また、鉄筋露出検出では学習画像枚数 2000 枚程度、金物腐食検出では 2500 枚程度で検出精度の向上が停滞することを確認した。

既報¹⁾では、金物腐食検出の TP Rate が 87% だったのに対し、本稿では金物腐食検出および鉄筋露出検出両方の TP Rate が 90% 以上であった。また鉄筋露出の検出精度の方が金物腐食よりも高くなった。これは、鉄筋露出の画像は金物腐食の画像に比べ汚れ等が写り込みづらく、劣化領域と非劣化領域の色情報による分類が容易であるためと考える。

4. 微小検出領域の除去によるセグメンテーション 深層学習検出結果の過検出抑制手法

本検討では、二値化処理を行った検出結果中から連結画素の大きさを求め、連結画素の大きさが一定値以下の場合に連結画素を削除する処理を加え、微細な連結画素を出力結果中から削除した。微細な連結画素の削除は、対象画素の 8 近傍を参照し、8 近傍に同一値が存在しない場合に 1 つの連結画素としてカウントし、連結画素の大きさが一定画素以下の場合に対象連結画素を削除した。削除する連結画素の大きさと検出画像の TP Rate および FP Rate の関係を図-3 に示す。鉄筋露出および金物腐食について、削

除する連結画素を大きくすると、TP Rate および FP Rate が減少することを確認した。鉄筋露出については、削除連結画素の大きさが 100 pixel より大きくなると、TP Rate が著しく減少する。金物腐食については、削除連結画素の大きさが 1000 pixel 以上になると、TP Rate が著しく減少する。そのため、各劣化においても、削除連結画素を大きくすることで過検出領域を削除可能であるが、TP Rate が著しく減少してしまう。そのため、画像中における検出対象物体の最低画素数や確保したい TP Rate の値から適切な削除連結画素の大きさを設定する必要がある。

本検討による微細な連結画素の削除を行うことで、セグメンテーション深層学習における検出結果中の過検出を抑制できることを示した。また本手法はマンホール内の劣化検出に限らず、他の物体の領域検出に対しても有効であると考えられる。

5. まとめ

本稿では、U-net によるマンホール内の鉄筋露出および金物腐食の劣化検出を学習画像枚数毎に評価した。その結果、学習画像枚数が一定数以上の場合、画像枚数に対する検出精度の向上が停滞することを確認した。また、画像処理により検出結果中の連結画素が小さいものを削除することで、過検出を抑制可能であることを示した。

参考文献

- 1) 内堀大輔ら：ドローンによる通信用マンホールの自動点検技術の開発，第 19 回建設ロボットシンポジウム論文集，O2-02，2019 年 10 月
- 2) Leslie N. Smith : Cyclical Learning Rates for Training Neural Networks, 2017 IEEE Winter Conference on Application of Computer Vision, March 2017