

## 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

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 柳 秀一

### 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、管路を橋梁の下部や側部に添架している。これらの設備を安全に維持するために定期的に点検を行っている。しかし、点検は近接目視により実施するため、足場を設置するための費用や危険な高所作業が課題となる。また、作業者の減少による点検品質の不均一さの課題がある。

既往研究では、カメラやドローンにより撮影した画像から劣化を自動的に検出する技術が提案されている<sup>1)</sup>。しかし、これらの方法は撮影画像に橋梁設備のみが写っている領域は劣化の検出が十分有効であるが、風景等の橋梁設備以外が写っている領域で誤検出が発生するため、適用には課題が残っている。

そこで我々は、橋梁の撮影画像から点検対象以外となる風景等の不要物を除去する画像処理方法の検討に取り組んだ。深層学習を用いて撮影画像からNTTが点検対象としている図-1に示す通信用管路と添架部材で構成される橋梁添架設備の領域検出を行った。

### 2. 橋梁添架設備の検出方法

撮影画像は風景等の様々な物体が写り込むことに加え、橋梁添架設備は添架する橋梁の形態により管路の塗料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、本稿では大量の画像データの学習を行い、画像中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。

#### 2-1. 領域検出モデルの構築

深層学習には様々な手法が存在するが、画像分類の分野で有効性の高い畳み込みニューラルネットワーク (CNN) を用いた。CNNは入力層、畳み込み層、プーリング層、全結合層、出力層で構成され、繰り返し訓練することで画像中の特徴量抽出を行い高精度の検出結果を得ることができる。本稿では、ILSCRC<sup>2)</sup>で発表さ

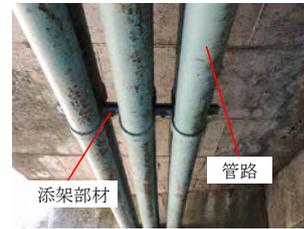


図-1 橋梁添架設備

れた学習モデルであるVGG16にFine Tuningを行った。Fine TuningはImage Netと呼ばれる大規模画像データベースによる学習済みモデルで計算された重みデータの一部を再学習により更新する手法である。重みの再学習は、具体的な特徴量を抽出する傾向が強くなる深い畳み込み層から全結合層まで実施した。

#### 2-2. 領域検出に用いるデータセットの作成

橋梁添架設備の領域判定は、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。撮影画像は縦480×横640 (pixel) に規格化した後、80×80 (pixel) の矩形領域に分割し (画像1枚当たり48枚の矩形画像の生成)、各矩形画像の30%以上の画素に橋梁添架設備が写っていれば、橋梁添架設備領域 (Positive)、それ以外を非橋梁添架設備領域 (Negative) と定義した。合計で1,248枚の撮影画像を用意し、900枚を学習用画像、100枚を検証用画像、248枚をテスト用画像に分類した。そして900枚の学習用画像からPositiveとNegativeの矩形画像を生成し、学習モデルによる再学習を行った後、248枚のテスト用画像の各矩形領域を判定し評価を行う。なお、事前に1,248枚の全画像において橋梁添架設備の領域にマスク処理が施されており、正解データがある状態である。

### 3. 領域検出率の検証方法

学習用画像900枚からPositiveとNegativeの矩形画像を最大40,000枚生成し、学習用矩形画像の枚数を変化させた際のテスト用画像の判定精度の評価を行った。学習モデルの再学習方法として、活性化関数はRelu、損失関数は二値分類問題で代表的な二値交差エントロピーを用いた。テスト用画像の評価は式(1)、式(2)に示

キーワード：橋梁添架、画像処理、深層学習、点検

〒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:029-868-6188

す正解率 (Accuracy) と  $F$  値を用いた。学習回数は 30 回を目安に行い、過学習が発生した場合は学習を停止した。学習用画像から生成される Positive と Negative の矩形画像を 5,000 枚~40,000 枚までの 8 パターンでの検証を実施した。

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

$$F = 2 \times \frac{TP}{TP+\frac{1}{2}(FP+FN)} \quad (2)$$

ここで、表-1 に示すように  $TP$  (True Positive) は、Positive を正しく予測したもの、 $TN$  (True Negative) は Negative を正しく予測したもの、 $FP$  (False Positive) は Negative を正しく予測できなかったもの、 $FN$  (False Negative) は Positive を正しく予測できなかったものである。

#### 4. 検証結果と考察

図-2 に矩形画像の学習枚数を変化させた際の Accuracy と  $F$  値の結果を示す。Accuracy と  $F$  値は、テスト用画像 248 枚の矩形領域の合計数で算出している。学習枚数を増やしていくと Accuracy と  $F$  値は共に上昇し、Accuracy の最大値は 0.81 (矩形画像 40,000 枚) であったが、学習枚数による著しい効果はなかった。

テスト画像の判定結果の一部を図-3 に示す。(a)は Accuracy が上位の画像であり、(b)は中位、(c)は下位の画像である。いずれの画像でも予測が上手くいった矩形画像は暗所や接写された領域や NTT の添架部材と類似した設備を含む領域である傾向が見られた。

表-2 に予測結果が False となった矩形画像の分類結果を示す。全体の約半数が類似設備となった。この要因として、学習時において通信用管路と見た目が類似した他社管路や NTT 設備ではない添架部材を Negative として定義したためである。次に割合が大きいものはコンクリートであった。これは、灰色のコンクリートは通信用管路に似ており、矩形領域内では区別が難しくなったためと考えられる。

今後の対策として、類似した他社管路や NTT 設備ではない添架部材の違いは判別が難しいと考えられるため、Positive として学習させて予測精度が向上するか検証を行いたい。また、コンクリートの領域に関しては管路と区別しやすくなるようにテクスチャ処理等の前処理を施した画像で学習を行う方法が考えられる。

#### 5. まとめ

本稿では、撮影画像から橋梁添架設備の領域を検出する画像処理方法の検討を行った。検出モデルの構築

表-1. 判定結果分類表

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

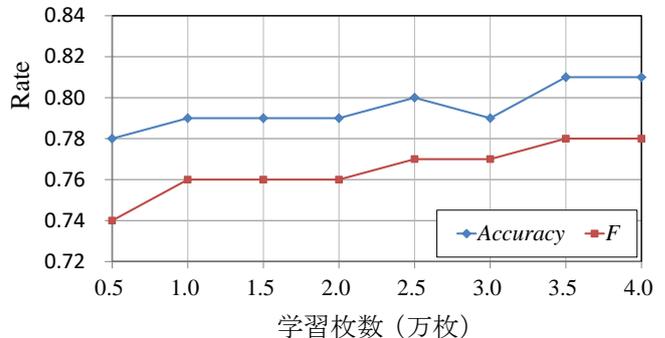
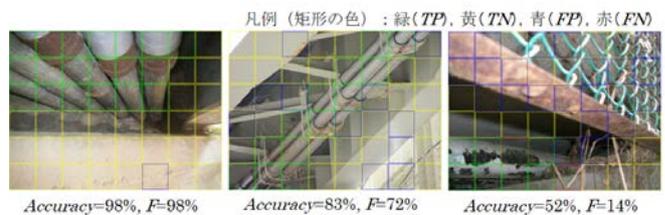


図-2. 各データセットの分類正解率



(a) 上位      (b) 中位      (c) 下位

図-3. テスト画像の判定結果

表-2. 判定結果が False となった矩形画像の分類

| 分類      | 白とび | 暗所   | 類似設備   | コンクリート | その他  | 合計     |
|---------|-----|------|--------|--------|------|--------|
| sample  |     |      |        |        |      |        |
| $FP+FN$ | 95枚 | 118枚 | 1,111枚 | 558枚   | 360枚 | 2,242枚 |
| 割合      | 4%  | 5%   | 46%    | 25%    | 16%  | 100%   |

には機械学習手法の一つである CNN を用いた。CNN への学習枚数を変化させた際の判定精度の検証を行った結果、最大 0.81 の精度を得たが、学習枚数を多くしても著しく精度の向上は見られなかった。事前に学習させる教師データに要因と推測されるため、今後は学習させる際の教師データの作成方法の変更や学習画像の前処理等を検討し、精度を向上させたい。

#### 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, 土木学会論文集 F4, Vol.74, No2, I\_62-I\_74, 2018
- 2) Stanford Vision Lab. : IMAGENET Large Scale Visual Recognition Challenge, 2017