

深層学習を用いた通信用とう道内の設備および劣化領域の検出技術

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
非会員 櫻田 洋介, 荒武 淳

1. はじめに

NTT アクセスサービスシステム研究所では、全国に総延長約 650km 存在する通信用とう道の安心安全な維持管理を目的として、画像解析を用いた点検技術の研究開発に取り組んでいる。現在、とう道の点検は作業者が目視で劣化を見つけ、大きさを計測しているが、本研究ではとう道の撮影画像から画像解析により劣化を検出し、劣化の大きさを自動的に計測する技術を用いて点検診断の自動化を図っていく。劣化の計測には、とう道に設置している通信ケーブルやケーブルを添架する金物などの設備の形状を用いる。これらの設備は、全て規格品であるため撮影画像における設備領域を高精度に検出すれば、同じ画像中の劣化の大きさを計測することができる。

本稿では、深層学習手法を用いて撮影画像から劣化と設備領域を高精度に検出することを目指し、学習時の損失関数に着目した。特徴の異なる 3 種類の損失関数を用いて、劣化と設備領域の検出を行った検討結果を示す。

2. 検出領域の特徴と従来モデルの課題

図-1 a)にとう道の撮影画像の例を示す。画像中のとう道の壁面は鉄筋コンクリート製であり、一部壁面には鉄筋露出が確認できる。また、通信ケーブルやケーブルを壁面に添架する筋金物と受金物がある。本稿では「筋金物」、「受金物」、「ケーブル」をとう道

内設備の検出対象とした。また、定期点検で対象項目となる劣化のうち、領域検出が有効な「漏水」、「剥離・剥落」、「鉄筋露出」の 3 種類を劣化の検出対象とした。さらに設備と劣化の領域以外の部分を「背景」と定義し、全 7 クラスを検出対象とした。

先に示した設備や劣化の検出対象となる物体の領域をマスキングした画像を図-1 b)に示す。さらに、学習や検証を行うとう道の画像 800 枚において、同様に検出対象領域をマスキングして、1枚あたりの検出対象領域が占める割合の平均値を示した結果を図-2 に示す。画像には様々な検出対象が含まれ、各種領域の占める割合は検出クラス毎に異なる。中でも背景クラスは画像中の 70%以上を占めており、実際に検出したい設備や劣化の領域は 12%程度の割合に留まることから、画像中の小さい領域も同時に検出することが求められる。

これらの各領域を検出するために、本検討では深層学習モデルのうち、Multiclass U-Net¹⁾を用いて検討することとした。しかしながら、前述したように、検出対象クラス間で領域の割合に差が大きい画像に対して、各領域を検出していく必要があり、最も対象領域が小さい鉄筋露出は従来モデルでは十分に検出できない可能性がある。このようなデータセットに対しては、微小な領域に対しても検出精度を向上させるために学習方法の改善が必要となる。本検討では、




図-1 RGB 画像と教師データ




図-2 各検出クラスの領域の割合

キーワード 画像処理, 深層学習, 通信用とう道, 点検, Multiclass 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-3 検出結果の一例




図-4 各損失関数の検出精度の比較結果

表-1 筋金物クラスを評価する際の混同行列

		予測値						
		筋金物	受金物	ケーブル	漏水	剥離	鉄筋露出	背景
真値	筋金物	TP	FN					
	受金物	FP	TN					
	ケーブル							
	漏水							
	剥離							
	鉄筋露出							
	背景							

学習時の指針となる損失関数として、微小な領域の検出に対応した 2 種類と従来モデル 1 種類の合計 3 種類を劣化と設備領域の検出精度の面から比較する。

3. 検討内容

本検討で用いる損失関数は、各クラスの対象領域の大きさで重み付けした Weighted cross entropy および F-measure の式の FN を大きく重み付けすることで小さい領域の検出に対応した Tversky²⁾とし、従来モデルで使用された Categorical cross entropy と比較する。なお、Weighted cross entropy の重み関数 w は、各クラスの領域差を表現するため、式(1)のように設定した。

w_i = N_i / n_i (1)

ここで、i: クラス番号、N: 画像全体の画素数、n: 対象クラスの画素数である。検出結果は図-3 のように出力され、モデルの評価には表-1 に例示する混同行列から式(2)、(3)で表される Recall および F-measure を算出した指標を用いた。

Recall = TP / (TP + FN) (2)

F-measure = TP / (TP + 1/2 * (FP + FN)) (3)

2つの指標を採用した理由は、劣化検出を行う場合には見落しなく検出必要があるため Recall が重要となり、以降検討する劣化領域の計測時には、設備の検出

結果が実際の領域を再現する必要があるため、F-measure が重要であると考えたためである。

4. 検討結果および考察

各損失関数で学習したモデルを用いて算出した Recall および F-measure の結果を図-4 に示す。図-4 a) のように Recall で比較すると、Weighted cross entropy が全クラスで最も大きい値を示し、特に小さい領域の鉄筋露出や受金物のクラスの Recall の向上が確認できる。これは小さい領域のクラスに大きく重み付けしたため、それらを逃さずに見つけるように FP を許容したことで Recall が向上した。一方、図-4 b) のように F-measure で比較すると、Tversky を損失関数としたとき、主に設備クラスで最も大きい値を示した。これは Tversky の損失関数が、F-measure を基にした関数となり、過検出や未検出を抑制し過不足なく実際に近い形状で検出できたことから F-measure が向上した。

5. まとめ

本稿では、とう道内の劣化検出および劣化計測技術の確立を目的として、劣化および設備の検出に関して最適な損失関数の検討を行った。とう道内の画像は検出対象物の領域に偏りが有ることから、Recall の向上には、各クラスの領域で重み付けした Weighted cross entropy、F-measure の向上には Tversky を損失関数として設定することが有効である。

参考文献

1) T. Hrkac et al., “Multiclass U-Net for Segmentation of Non-Biometric Identifiers,” IMVIP, pp. 131-138, 2018.
2) S.S.M. Salehi et al., “Tversky loss function for image segmentation using 3D fully convolutional deep networks,” MLMI, pp. 379-387, 2017.