

教師なし深層学習による RC 床版画像生成と劣化指標の可視化

八千代エンジニアリング 正会員 ○関口 齋治, 正会員 野田 一弘, 正会員 中島 道浩,
八千代エンジニアリング 非会員 岡野 将大, 非会員 安野 貴人

1. はじめに：教師なし損傷検知と劣化指標

橋梁の老朽化に伴い、予防保全のため、点検と診断の重要性が増している。目視点検画像が多く蓄積されているが、人の判定は柔軟である反面、個人差を含み、客観的な劣化指標が求められている。点検項目 26 の半数は発生頻度が低くデータ蓄積に長期間を要する。教師あり学習は、未経験のデータ（学習の盲点）に対し頑健でなく、不正解や見落しが懸念される。一方、医療・製造業・食品・材料や X 線荷物検査では、教師なし深層学習による画像生成と異常検知が用いられている。橋梁の目視画像で、対象との距離・角度を許容範囲に制御し、背景ノイズを除去し、コンクリート（以下、CO と略記）表面に焦点を当てた単位画像を生成できれば、画像生成と異常検知の適用が可能であろう。教師なし深層学習は、未経験の損傷有無を検知できる利点があり、健全な状態からの距離を表現した劣化指標のスコアリングが可能となる。

本稿では、橋梁 RC 床版を対象に、画像生成による異常検知アルゴリズム適用を試みる。サイズの異なる点検画像をパッチ画像に分割し、CO 画像を分類抽出する。健全か損傷ありか検知するため、元画像 real と生成画像 fake の差分抽出を行うとともに、検知誤差を抑制する劣化指標の閾値を検討する。

2. 目視点検画像からパッチ画像の分割

本稿では、近接目視点検による直轄橋梁の RC 床版の画像 10,400 枚を用いる。各画像は、対象との距離、角度、日照条件が多様に異なる（図 1）。画像サイズ（pixel）の高さは 360～2,419 で、幅は 480～3,226 と規模が異なる。サイズ別の集計では、高い解像度の方から、1,500～2,419×2,000～3,226 の huge サイズは N=1,184 枚で、1,000～1,500×1,500～2,000 の large サイズは、N=2,281 であった。残りの small サイズ N=6,988 枚は解像度が低下し、学習・推論の適用に耐えない。本稿では、huge サイズを対象に、パッチ画像を分割処理する。パッチ画像の単位サイズを 256×256 と設定し、具体的な縦横サイズに即し、

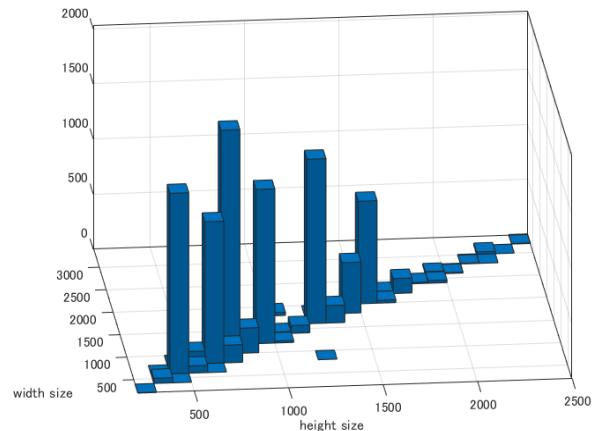


図 1 RC 床版の点検画像の縦横サイズ（pixel）の分布
切れ端の損失を最小化するように、 $6 \times 8, 4 \times 6, 4 \times 5, 3 \times 5$ と分割数を調整し $N=56,832$ 枚を得た。ここで、元画像のリサイズは行わず、ピクセルの特徴量を保持し統一サイズのパッチ画像を切出した。

3. パッチ画像の分類器とコンクリート画像抽出

パッチ画像には、桁・排水管の鋼材、RC 床版の CO が様々な割合で含まれる。本稿では、CO の損傷に着目する。画像生成による異常検知のためには、健全な CO 部材に焦点を当てたデータセットが必要である。背景の空や雑草のノイズを含まない CO 表面純度 100% のパッチ画像を抽出する。まず、 $N=2,010$ 枚のパッチ画像を橋梁単位で抽出した初期画像に対して、7 クラスの種類を設定し、目視で仕分けた（表 1）。

表 1 パッチ画像の分類クラスの設定と学習用データ数

クラス	初期学習	2 次学習
C1. 健全・損傷を含む CO 画像	530	2,031
C2. 背景と CO の混合	86	251
C3. 背景（空・雑草）	102	324
C4. 鋼材（塗装部）	569	2,153
C5. 鋼材と CO の混合	539	1,516
C6. 真っ暗で CO が不鮮明	184	690
C7. 鋼材の顕著な腐食、錆汁	-	85
学習用データセット合計	2,010	7,050

初期画像 $N=2,010$ 枚を対象に、分類器を深層学習し、2 次データセット $N=7,050$ 枚を推論出力し、不正解のクラスがないか出力画像を精査し修正した。さらに、3 次データセット $N=10,000$ 枚を推論出力し、学習用のデータセット $N=17,003$ 枚を整備した。画像全体が

キーワード 橋梁目視点検、教師なし深層学習、パッチ画像分類、コンクリート画像生成、劣化指標。

連絡先：〒111-8648 東京都台東区浅草橋 5-20-8 CS タワー TEL 03-5822-6219.

真っ暗、不鮮明な47枚を除外した。本格構築を行い、その分類器を用いて、どのクラスが正解かわからぬ残りの39,744枚を推論出した（表2）。

表2 コンクリート画像抽出用の分類器構築と推論出力

クラス	本格構築	推論出力
C1. コンクリート Co. 画像	4,029	17,727
C2. 背景と CO の混合	790	1,390
C3. 背景（空・雑草）	914	767
C4. 鋼材（塗装部）	5,671	8,896
C5. 鋼材と CO の混合	3,971	6,923
C6. 真っ暗で CO が不鮮明	1,226	3,738
C7. 鋼材の頗著な腐食、錆汁	402	303
学習用データセット合計	17,003	39,744

分類器の背骨ネットワークに、速度・精度ともに効果的な ShuffleNet, ResNet101 を設定し、学習評価した。3段階の構築で、それぞれデータ数を9:1に分割、学習・評価に用いた。ミニバッチ32、最適化手法 RMSProp、30エポックの反復計算を実行し、評価用1割の精度を比較した（表3）。

表3 パッチ画像の分類器の評価用精度

Model	初期	2次学習	本格構築
ShuffleNet	85.57%	82.81%	80.44%
ResNet101	88.50%	82.95%	84.34%

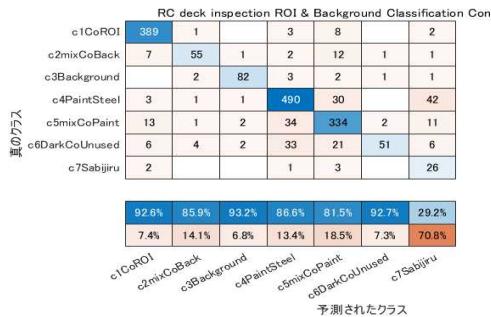


図2 ResNet101による7クラス分類器精度（混合行列）

4. 教師なし深層学習による画像生成と損傷検知

健全なCO画像のみを抽出するため、N=17,727枚から初期原型用にN=2,019枚を抽出し、健全、エフロレッセンス、損傷ありの3クラス分類器を構築した。Uncertainは、分類確率に曖昧さが残り、各クラスの最大確率が0.9を下回る $\max_k \{prob(k)\} < 0.9$ の条件を満たす場合に、判定が割切れない不確定な画像として振り分けた。本格構築では、ResNet101の分類器で、評価用の精度が85.84%に安定した。健全なCO画像N=7,494枚を用いて、画像生成ネットワークを学習した¹⁾。損傷ありの画像N=4,057枚から、鉄筋露出のテスト画像を作成した。ひび割れも作成したが紙面の都合上、割愛する。健全・損傷ありの元画像(real)を画像生成により、健全な状態の生成画像(fake)に変換し、realとfakeの差分を出した

表4 画像生成データ用の分類AI構築と推論出力

クラス	初期原型	本格構築	推論出力
C1. 健全	1,096	2,156	7,494
C2. エフロレッセンス	407	698	3,220
C3. 損傷あり	251	529	4,057
E. Uncertain(prob<0.9)	265	88	2,956
学習データセット合計	2,019	3,471	17,727

(図3)。上2段の元画像が健全な場合、差分に変化はない。一方、下3段の鉄筋露出の元画像は、損傷部の差分が検出できている。健全な状態からの距離を表す劣化指標(anomaly score)のヒストグラムを示す(図4)。劣化指標30を閾値とすると、健全・損傷ありの検知が精度よく可能となり、不正解と見落とし(precision, recall)の誤差を抑制できる。



図3 元画像と生成画像との差分出力（教師画像なし）

(上段2行：健全、下段：鉄筋露出)

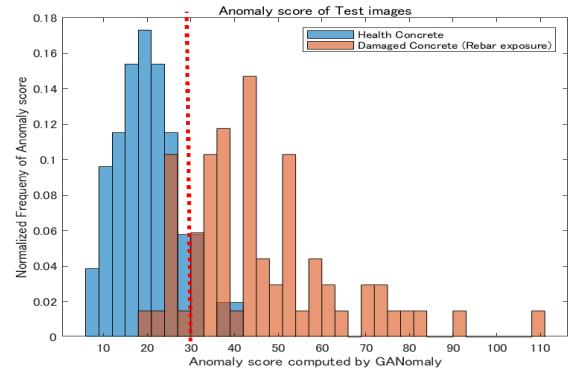


図4 劣化指標のヒストグラム（健全、鉄筋露出）

5. おわりに：劣化指標の可視化

本稿では、教師なし深層学習により画像生成による鉄筋露出の損傷検知を可能とする劣化指標を提案した。今後、劣化指標と判定区分の1次近似、分類と損傷検知のAIパイプライン構築、画像サイズと損傷検知のFeasibility/Ablation Studyが課題である。

謝辞：RC床版画像は、土木研究所変状抽出SWGで、研究目的の使用機会を頂いた。感謝の意を表します。

参考文献

- Akcay, S., A-Abarghouei, A., and Breckon, T.P.: GANomaly: Semi-Supervised Anomaly Detection via Adversarial Training, arXiv:1805.06725v3, 2018.