

# 機械学習を援用した可視・赤外線画像によるコンクリート道路擁壁の損傷検出

## Damage Detection of Concrete Road Wall using Visible and Infrared Images with Machine Learning Methods

○宮本真歩\* 柴野一真\*\* 島本由麻\*\*\* 鈴木哲也\*\*\*\*

○Maho MIYAMOTO, Kazuma SHIBANO, Yuma SHIMAMOTO, and Tetsuya SUZUKI

### 1. 背景

現在一般的に用いられる、検査員の目視による点検は、表面の損傷を正確に検出する反面、検査員の技量と多大な労力を要する。そのため、機械学習を用いた、画像解析によるコンクリートの損傷検出手法は多く提案されている<sup>1)</sup>。また、画像からの損傷検出には、可視画像のみでなく、構造物内部の状態が推察可能な赤外線画像も利用されている<sup>2)</sup>。本報では、損傷が進行した鉄筋コンクリート道路擁壁(1973年に竣工)を対象とし、UAVを用いて撮影した可視画像と赤外線画像を組み合わせ、機械学習を用いた表面損傷検出手法を提案する。

### 2. 実験方法

UAVに可視カメラ、受動型赤外線カメラを搭載し、道路擁壁の一つのパネルが一枚の画像に収まるように、8時から2時間おきに計5回撮影した。撮影した可視画像と赤外線画像を重ね合わせ、パネル部分のみを抽出した。パネル画像は計7つで、画像内の1型枠が16分割になるように矩形に分割し、この矩形(以後セル)ごとに無損傷、ひび割れ、断面欠損、ノイズ(植生)、影の5クラスに手でラベリングした。機械学習はランダムフォレスト(以後RF)、SVM、ニューラルネットワーク(以




Fig. 1: パネル1の可視画像からの特徴量抽出  
Feature extraction from visible images in panel 1

後NN)を使用した。また、機械学習に用いる特徴量(説明変数)は以下とした。

#### (1) ケース 1: 可視画像のみを用いて機械学習

RGB値とHSV値のセルごとの平均値、標準偏差、最大値、最小値(計24)を特徴量とした。

#### (2) ケース 2: 可視画像と赤外線画像を用いて機械学習

ケース1の特徴量に加え、16時の温度および16時と10時の温度の差の二乗値におけるセルごとの平均値、標準偏差、最大値、最小値、最大値と最小値の差(計34)を特徴量とした。

機械学習の特徴量として可視画像のみを使用した場合と、可視画像と赤外線画像を組み合わせた場合の分類精度の違いを比較した。

### 3. 実験結果

Table 1に各ケースにおける機械学習手法ごとの損傷分類結果を示す。可視画像と赤外線画像の特徴量を学習させたケース2では、すべての機械学習手法において可視画像のみを学習させたケース1よりも優れた分類精度

\*東京農工大学農学府 Graduate School of Agriculture, Tokyo University of Agriculture and Technology

\*\*新潟大学大学院自然科学研究科 Graduate School of Science and Technology, Niigata University

\*\*\*東京農工大学大学院農学研究院 Institute of Agriculture, Tokyo University of Agriculture and Technology

\*\*\*\*新潟大学自然科学系(農学部) Institute of Agriculture, Niigata University

キーワード: 鉄筋コンクリート, 維持管理, 画像解析, 機械学習

を示した。RF は機械学習手法の中で最も正解率が高く、ケース 1 では 88.0%，ケース 2 では 90.1%であった。RF は特徴量の標準化が必要なく、堅牢性の高いアンサンブル学習であることがほかの手法と比較して分類精度が優れた要因の一部であると推察される。

Table 2 に最も正解率の高い RF によるケース 2 の混同行列とクラスごとの評価指標を示す。F 値の高い順に影、ノイズ、断面欠損、無損傷、ひび割れであった。混同行列はひび割れと無損傷の 2 クラス間での誤分類が多いことを示している。遠方からの撮影により画像の解像度が低く、ひび割れ幅の小さいひび割れと無損傷との差別化が難しいためであると考えられる。

Fig. 2 に SHAP 値 (Shapley additive description value) の絶対値の平均の大きい順に上位 20 の特徴量を示す。SHAP 値とは、ある特徴量を追加した際の予測値の変動量をその特徴量の限界貢献度として計算し、全ての特徴量の組み合わせの限界貢献度を平均した値であり<sup>3)</sup>、大きいほど有効な特徴量であることを示す。影は一様に温度が低いいため、温度の特徴量(特に T\_ave)、ノイズは植生で擁壁とは色が異なるため、RGB 値の特徴量(特に B\_min) の SHAP 値が大きい。無損傷、ひび割れ、断面欠損は温度の特徴量(特に T\_ave, T\_min) の SHAP 値が大きい。これは、コンクリート表面の損傷領域に入射した熱が空隙内で細かく反射され温度が上昇する空洞放射という現象が起こったためであると考えられる。

#### 4. まとめ

本報の損傷分類において、ランダムフォレストによる分類が SVM, ニューラルネットワークよりも優れていた。可視画像のみを使用したケース 1 よりも可視画像と赤外

Table 1: ケース 1, 2 における機械学習手法ごとの結果  
Results for each machine learning method in Case 1 and 2

| 指標  |       | 方法    |       |       |
|-----|-------|-------|-------|-------|
|     |       | RF    | SVM   | NN    |
| 正解率 | ケース 1 | 0.880 | 0.870 | 0.820 |
|     | ケース 2 | 0.901 | 0.874 | 0.883 |
| 再現率 | ケース 1 | 0.826 | 0.810 | 0.711 |
|     | ケース 2 | 0.857 | 0.816 | 0.838 |
| 適合率 | ケース 1 | 0.833 | 0.824 | 0.758 |
|     | ケース 2 | 0.869 | 0.840 | 0.821 |
| F 値 | ケース 1 | 0.829 | 0.817 | 0.712 |
|     | ケース 2 | 0.862 | 0.826 | 0.828 |

Table 2: RFによるケース2の混同行列とクラスごとの結果  
Confusion matrix for Case 2 with RF and result for each class

| 正解率 | 0.901 |       |       |       |       |       |
|-----|-------|-------|-------|-------|-------|-------|
| クラス | 無損傷   | ひび割れ  | 断面欠損  | ノイズ   | 影     | 平均    |
| 再現率 | 0.791 | 0.732 | 0.796 | 0.980 | 0.985 | 0.857 |
| 適合率 | 0.739 | 0.756 | 0.896 | 0.961 | 0.991 | 0.869 |
| F 値 | 0.764 | 0.744 | 0.845 | 0.971 | 0.999 | 0.862 |

| 機械学習による予測 |      |     |      |      |     |     |
|-----------|------|-----|------|------|-----|-----|
| 真値        | クラス  | 無損傷 | ひび割れ | 断面欠損 | ノイズ | 影   |
| 真値        | 無損傷  | 102 | 23   | 1    | 1   | 2   |
|           | ひび割れ | 30  | 90   | 2    | 0   | 1   |
|           | 断面欠損 | 4   | 6    | 43   | 1   | 0   |
|           | ノイズ  | 1   | 0    | 2    | 149 | 0   |
|           | 影    | 1   | 0    | 0    | 4   | 331 |




Fig. 2 : 各特徴量のSHAP値(上位20まで)  
\*ここで、特徴量について、RGB値とHSV値はそれぞれの頭文字、Tは16時の温度、Tdfは16時と10時の温度差の2乗である。\_aveは平均値、\_sdは標準偏差、\_minは最小値、\_maxは最大値、\_dfは最大値-最小値を表す。

線画像を併用したケース 2 は全ての機械学習手法において損傷分類精度が高かった。また、ひび割れ等損傷の分類には温度の特徴量が特に有効であった。

#### 参考文献

- 1) Ai, D., Jiang, G., Lam, S.K., He, P., Li, C., "Computer vision framework for crack detection of civil infrastructure—A review", Engineering Applications of Artificial Intelligence Vol.117, Part A, 2023.
- 2) Ichi, E., Dorafshan, S., "Effectiveness of infrared thermography for delamination detection in reinforced concrete bridge decks", Automation in Construction Vol.142, 104523, 2022.
- 3) Lundberg, S.M. and Lee, S.I., "A unified approach to interpreting model predictions", Advances in Neural Information Processing Systems, 30.