

UAV 画像の深層学習による農道橋 RC 床版のひび割れ検出

Crack Detection for RC Slabs of Rural Road Bridge

by Deep Learning with UAV-imagery

○田中熙*・柴野一真**・Nadezhda MOROZOVA**・向井萌華**・鈴木哲也***

○Hiromu TANAKA*, Kazuma SHIBANO**,

Nadezhda MOROZOVA**, Moeka MUKAI** and Tetsuya SUZUKI***

1. はじめに

近年、コンクリート構造物を対象としたひび割れ検出に深層学習が適用されている。コンクリート構造物は表面の凹凸や汚れ、日射の違いによる色相の差等、ノイズを多く含んでいるため誤検出しやすいことがよく課題として挙げられる。既往研究では、その対策として画像のコントラスト向上のための前処理を加える方法¹⁾、多様なシーンに対処する大規模なデータセットを用いる手法²⁾や可視画像に加え熱画像などの情報を併用する方法³⁾が検討されてきた。本研究で対象とした画像は日射の当たり方が多様であり、日射によってひび割れの特徴量に変化している。

そこで本研究では、検出モデル作成の前に日影判定を加え、ひび割れを日影、日向、日影と日向の3種類に分け個別に解析し、前処理の有無による検出精度の差を特定することを試みた。

2. 計測および解析方法

2.1. 対象構造物と取得画像

対象は1998年に竣工した新潟県柏崎市に位置する清水谷大橋の舗装の一部である。目視観察では、特に主桁ウェブ位置直上に舗装ひび割れが確認された。可視画像はMatrice210(DJI社)に搭載したZenmuseXT2により取得した。カメラの技術仕様である焦点距離は8mm、画像幅の画素数は4,000pixelsおよび撮像素子サイズは7.5mmであ

る。効率的な画像取得のため幅員が画角となるようUAV高度を5mに調整した。UAV高度とカメラの技術仕様の関係から地上サンプリング距離(GSD)は0.12cm/pxに設定された。

2.2. 解析方法

取得した可視画像はひび割れ部と非ひび割れ部に分類し、アノテーション処理を行った。分類対象としたクラスはひび割れ部、ひび割れ以外である。また、それぞれの画像は128pixel四方に切り取った。舗装上の白線や植生を含む無処理(Case 1)、日影(Case 2)、日向(Case 3)、日影と日向の両方(Case 4)のひび割れデータを学習させ、テストデータとしてひび割れ幅を計測した計20枚のデータを用いた。各ケースの枚数はそれぞれ1,035枚、112枚、111枚、88枚である。ひび割れ検出モデルにはU-Netを用いた。U-Netは局所的かつ大局的な特徴を抽出するため、高精度なセグメンテーションが可能である。解析で設定したハイパーパラメータはチャンネル数8、バッチサイズ、カーネルサイズ5、最大エポック数50、プーリング数2である。検出精度は精度、適合率、再現率およびF値を用いた。

3. 結果および考察

3.1. ひび割れ検出結果

各ケースにおける光条件の異なるひび割れの検出結果を図-1と表-1, 2に示す。図-1と表-1は日向部、暗い影部、明るい影部、

* 新潟大学農学部 Institute of Agriculture, Niigata University

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

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

キーワード: U-Net, 画像処理, 光条件, 農業インフラ, コンクリート

日影と日向部に位置するひび割れの検出結果を各ケースで示したものである。Case 1 の F 値が最も低く、また各ケースが学習した特徴の検出精度は安定して高かった (図-1 内赤枠, 表-1 内赤字)。表-2 は、光条件の異なる画像に対する各評価指標をケースごとに比較したものである。Case 1 は再現率や F 値が他のケースよりも低い。Case 1 は光条件を考慮した判定を加えておらず、データセット内のひび割れ率が小さいため、過小評価したモデルであると考えられる。F 値は Case 2, Case 3 が特に高く、このことから、検出モデル作成前に特徴が類似したデータセットに限定することで、検出精度がより高まると考えられる。

3.2. ひび割れ幅による検出精度の違い

日向部におけるひび割れ幅と各ケースの F 値の関係を図-2 に示す。ひび割れ幅が大きくなるにつれて検出精度が大きくなると予想したが、そのような傾向は確認されなかった。データセットの光条件とひび割れ幅のバランスが異なるため、差が見られなかったものと考えられる。

4. おわりに

本研究では、UAV 画像を用いて U-Net により農道橋 RC 床版部のひび割れを検出した。その結果、日影や日向といった類似の光環境毎に学習させることで検出精度が向上し、高精度な検出が可能となった。今後は、日影や日向以外の特徴に着目し、より汎用的な検出フローを検討する必要がある。

引用文献

- 1) 島本由麻, 鈴木哲也 (2023): ヒストグラム平坦化を活用した道路橋床版での遊離石灰の自動検出に関する解析的検討, 農業農村工学会論文集, 91(1), I_69-I_76.
- 2) Gopalakrishnan, K., Khaitan, S. K., Choudhary, A. and Agrawal, A. (2017): Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection, Construction and building materials, 157, 322-330.
- 3) Shibano, K., Morozova, N., Shimamoto, Y., Alver, N. and Suzuki, T. (2024): Improvement of Crack Detectivity for Noisy Concrete Surface by Machine Learning Methods




図-1 各ケースにおける検出結果比較

表-1 各光条件における F 値

ケース	日影 (暗)	日影 (明)	日向	日影と日影
Case 1 (無処理)	0.000	0.542	0.391	0.155
Case 2 (日影)	0.429	0.575	0.586	0.511
Case 3 (日向)	0.450	0.481	0.658	0.378
Case 4 (日影と日向)	0.282	0.452	0.595	0.498

表-2 ひび割れ全体の検出精度比較

ケース	精度	適合率	再現率	F値
Case 1 (無処理)	0.969	0.889	0.205	0.333
Case 2 (日影)	0.971	0.700	0.387	0.498
Case 3 (日向)	0.972	0.777	0.336	0.469
Case 4 (日影と日向)	0.971	0.776	0.302	0.435




図-2 日向部のひび割れ幅と F 値の関係

and Infrared Images, Case Studies in Construction Materials, e02984.