

## コンクリートのひび割れ検出 AI の有効性と課題 Effectiveness and Issues of AI Detecting Cracks in Concrete

木村 優世\*, 川邊 翔平\*, 金森 拓也\*

KIMURA Yusei, KAWABE Shohei, KANAMORI Takuya

### 1. はじめに

農業水利施設の多くを占めるコンクリート構造物は、戦後から高度経済成長期にかけて集中的に整備され、現在一斉に老朽化が進行している。そのため、施設の長寿命化、またライフサイクルコスト低減の観点から、これらの施設の点検・診断の必要性がより一層高まっている。ひび割れは、コンクリート構造物において頻繁に見られる変状の1つであり、点検項目としても重要である。しかし、ひび割れの点検は、近接目視とスケール等を用いた計測によって行われるため、長時間の作業になることや、集中力の低下による見逃しの発生などが課題となっている。そのため、近年は AI 等の新技術の研究・開発が行われており、点検の省力化・高度化が図られている。本発表では、深層学習による画像解析でよく用いられる手法の画像分類と物体検出、そして文献の少ない異常検知について、有効性を比較・検証し、課題の抽出を行う。

### 2. データセットと AI の概要

#### 2. 1 データセットの概要

データセットは、発表者がデジタルカメラ (Canon PowerShot SX740) を用いて撮影した画像 300 枚で構成される。300 枚の画像には、ひび割れを含まない画像 (正常画像) とひび割れを含む画像 (ひび割れ画像) が、それぞれ 150 枚ずつ含まれている。

AI モデルの作成においては、学習データ (画像) の量が重要であり、300 枚は非常に少ないと言える。しかし、インターネット上に公開されているデータセット<sup>1),2)</sup>から 4,000 枚の画像を抽出し、同様の検証を行った場合においても、今回は結果に大きな差が見られなかったため、本発表においては自身で撮影した画像で学習したモデルを検証対象とする。

#### 2. 2 ひび割れを検出する AI

本検証のひび割れ検出に用いる AI は以下の 3 種類である。

- (1) 異常検知 (VAE : 変分自己符号化器) : 正常画像のみを用いて学習を行い、設定された閾値以上の差異が検出された場合に「異常」、閾値以下であった場合には「正常」と判定する。なお、入力画像サイズは  $64 \times 64$ 、学習率は 0.001、エポック数は 30 とする。
- (2) 画像分類 (ResNet18) : 正常画像、ひび割れ画像の両方を用いて学習し、画像中にひび割れが含まれているか否かを判定する。なお、入力画像サイズは  $298 \times 224$ 、学習率は 0.001、エポック数は 50 とする。
- (3) 物体検出 (YOLOv5m) : あらかじめひび割れの位置をラベリングした画像を用いて学習し、結果として出力した画像では、ひび割れ領域をボックスで囲むことにより、その位置まで示す。なお、入力画像サイズは  $800 \times 600$ 、学習率は 0.01、エポック数は 300 とする。

---

\*農業・食品産業技術総合研究機構 農村工学研究部門 Institute for Rural Engineering, NARO

キーワード 深層学習, AI, コンクリート, ひび割れ

### 3. 結果

#### (1) 異常検知 (VAE)

異常検知による適合率 (Precision) と再現率 (Recall) の関係を図 1 に示す。図 1 に見られるように、適合率と再現率はトレードオフの関係であり、検出漏れを減らすよう閾値を小さくすると誤検出が多くなる。

また、ひび割れ画像を正しく「異常」と判定した例を図 2 に示す。図中に示しているように、異常判定の場合においても、異常を検出した箇所がひび割れ部と異なるケースも見られた。

#### (2) 画像分類 (ResNet18)

図 3 に、画像分類によって、ひび割れ部を根拠とし、「ひび割れ画像」と正しく判定した例を示す。全体の正解率 (Accuracy) は 88 % となったが、画像分類においても、ヒートマップを用いて、分類に影響した箇所を可視化すると、異常検知と同様にひび割れ部以外を判定の根拠としているケースも見られた。

#### (3) 物体検出 (YOLOv5m)

物体検出の評価指標である  $mAP_{50}$  は 0.24 となった。また、結果として出力された画像を見ると、過剰に検出する傾向が見られ、ひび割れのない箇所においても濃い影が入っている場合などは誤検出されやすいと考えられる (図 4)。一方、「異常検知」や「画像分類」において見られた日当たりの違い等による誤検出 (図 2) は見られなかった。

### 4. おわりに

コンクリートのひび割れを検出する 3 種類の AI の検証より、コンクリート画像は、基本的にグレー一色の特徴の少ない画像であることから、日当たりの違いや表面の小さな凹凸、汚れ等のノイズの影響が大きく、誤検出が起りやすいという課題が確認された。しかし、日当たりの違いや汚れによる誤検出はラベリングを行うことにより抑制することができた。また、ラベリングを行って学習した物体検出からは、AI が学習したひび割れの特徴が「黒と他の色 (グレー) の境界」である可能性が示された。

これらの課題を解決するためには、学習前に行う画像処理が重要となると考えられる。具体的には、変状領域のラベリングの他に、日当たりの違いや表面の小さな凹凸、汚れ等のノイズを低減し、相対的にひび割れを強調するような前処理が有効となると考えられる。

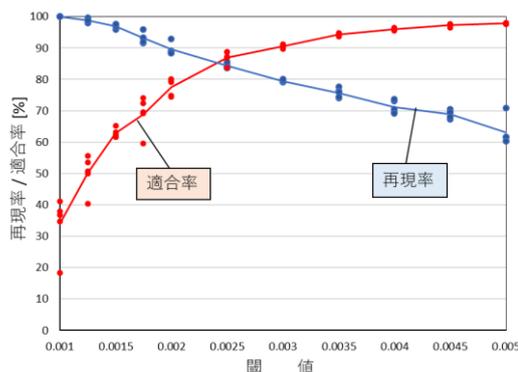


図 1 異常検知の閾値と再現率/適合率の関係

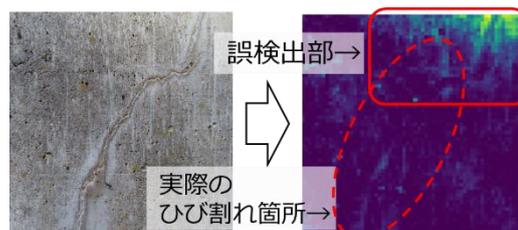


図 2 異常検知の例 (判定: 異常)

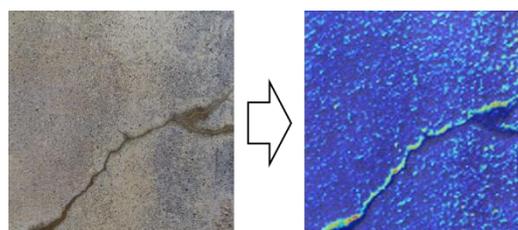


図 3 画像分類の例 (判定: ひび割れあり)  
※右はヒートマップ画像

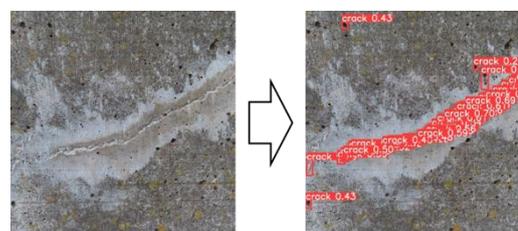


図 4 物体検出の例

1) Concrete Crack Images for Classification

2) SDNET2018: A concrete crack image dataset for machine learning applications