

赤外線サーモグラフィによるスラブ下部の診断法に関する基礎研究 その2 画像認識 AI による浮き箇所の推定

正会員 ○古谷 勇人*¹ 同 青山 浩之*¹
同 平間 寛子*² 同 八幡 邦哉*³

橋上駅舎 赤外線サーモグラフィ 床スラブ
浮き コンクリートスラブ 画像認識 AI

1.はじめに

前報では、赤外線サーモグラフィを用いた構造物表面の最適な撮影時間について検討を行い、この技術を点検業務に導入する可能性が示された。一方で、赤外線サーモグラフィ画像から変状の有無を判断する際には、評価者間で判定結果にばらつきがあることが課題として挙げられている。そこで本研究では、変状箇所の内、「浮き」を対象に、画像認識 AI を用いた赤外線サーモグラフィ画像からの推定により、浮きの簡易かつ客観的な判定の可能性を検討した。

2. 検証項目の設定

画像認識 AI を用いた赤外線サーモグラフィ画像からの浮き箇所推定を定性的および定量的に検証する項目を設定した。検証項目を表 1 に示す。

表 1 検証事項

検証項目	仮説
浮き箇所検出	画像から浮き箇所を自動検出できる
浮き範囲数値化	検出した浮き範囲を面積比率として表現できる

表 1 の仮説を検証することにより画像認識 AI を用いることで、浮き箇所検出と浮き範囲の数値化が可能であると考えられる。

2-1. 浮き箇所検出

浮き箇所検出 AI モデルを構築した。対象画像には、駅舎の橋上駅スラブ下部を撮影した赤外線サーモグラフィ画像を用いた。撮影可能な箇所が限られていたため、同一対象につき、3~4 枚の異なる画角で撮影し計 155 枚の画像を収集した。構築は、図 1 に示すように、教師データ作成、モデル学習、モデル評価という 3 工程から構成される。




図 1 物体検出 AI の開発工程

教師データの作成に際し、浮きと判断された箇所に対して正解付け（アノテーション）を実施した。正解は、

赤外線建物診断技能士による判断とした。学習用データとして教師データの約 80%である 125 枚の画像を使用した。

学習用 AI モデルは、YOLOv8（You Only Look Once version 8）のセグメンテーションモデルを採用した。²⁾ YOLOv8 は、学習済みのモデルが公開されているため、学習時間低減および高精度化が期待できる。またセグメンテーションは、画像内の対象物をピクセル単位で領域分類することであり、浮き箇所検出の目的に則した手法である。

本画像は温度情報に基づいて形成される疑似カラー変換画像であるため、通常の可視画像とは異なり色情報やエッジ特性に差があり、可視画像による AI モデルとの親和性に懸念がある。また、学習用教師データ数が限られていたため、データ拡張処理により教師データ数を約 20 倍に増加させた。データ拡張の例を図 2 に示す。




図 2 データ拡張の例

2-2. 浮き範囲数値化

構築した浮き箇所検出モデルは、浮き箇所の位置情報に加え、画像内のピクセル面積が取得可能である。浮き範囲数値化として、浮き範囲のピクセル面積を画像中全体のピクセル面積で除することで面積比率を算出した。

3. 検証結果

3-1. 浮き箇所検出

評価用データである 30 枚の画像に対し、構築した浮き箇所検出モデルによる推定を行った。推定結果の例を図 3 に示す。なお検出した浮き箇所は青枠で示した。




図3 正解データ(左) 検出結果(右)

図3に示すとおり、正解データの4箇所を含む、5箇所を浮き箇所として検出された。

浮き箇所検出モデルの性能およびデータ拡張処理による効果を確認するため、学習に使用していない画像30枚を用いて検証した。評価のためデータ集計により混同行列を作成し、指標となるIoU(Intersection over Union)、再現率(Recall)、適合率(Precision)の3つを算出した。IoUは予測範囲と正解範囲の重なり具合を示す指標であり予測領域がどれだけ正解領域と一致しているかを表し、再現率は実際に正解であるものをどれだけ予測できたかの割合を表し、適合率は正解と予測したデータのうち実際に正解であるものの割合を表す。混同行列は、ピクセルベースで浮き箇所を正、そうでない箇所を負として正解データと検出結果の一致・不一致を累積的に集計したものである。評価指標は混同行列により算出した。集計した混同行列を表2に、各評価指標を表3に、それぞれ示す。

表2 混同行列

データ拡張なし				データ拡張あり			
		正解				正解	
		正	負			正	負
予測	正	23,972	13,223	予測	正	51,216	13,606
	負	83,771	5,063,034		負	56,527	5,062,651

表3 各評価指標

	データ拡張なし	データ拡張あり
IoU	0.20	0.42
再現率	0.22	0.48
適合率	0.64	0.79

表3に示すとおり、IoUは、データ拡張なしが0.20、データ拡張ありが0.42であった。全ての指標はデータ拡張なしよりデータ拡張ありが高い結果であった。データ拡張処理により、検出精度が向上したといえる。また構築した浮き箇所検出モデルは、適合率が0.79であることから予測した浮き箇所の確からしさは高いものの、再現率が0.48と予測できていない浮き箇所が存在するモデルであるといえる。本モデルでは、データ収集時および学習時にデータ拡張を行ったものの、異なる浮き事例に対す

るデータが不足していたため、検出モデルの汎化性能が十分に得られず、IoUや再現率の向上には至らなかった。一方で、限られた条件下でも0.79の適合率を達成できたことから、モデルとして一定の安定性は確保されていると判断でき、赤外線サーモグラフィ画像による浮き箇所の定性的な検出可能性が示唆された。

3-2. 浮き範囲数値化

構築した浮き箇所検出モデルの予測結果から、浮き範囲数値化を実施した。実施結果の例を図4に示す。




図4 変状箇所の面積比率の検出結果

図4に示すように検出された浮き箇所は、青色で網掛けすることで範囲を視覚的に明示し、それぞれの面積比率をパーセントで示した。また、画像内における浮き箇所の総面積比率を画像右下に記載した。この検出結果から浮き範囲を面積比率で表すことができ、定量評価の可能性が確認できた。従来は熟練者に依存していた危険箇所の優先順位付け等は、面積比率による閾値設定や数値比較による方法を検討でき、簡易かつ客観的に実施する手法としての可能性が示唆された。

4. まとめ

本研究では、画像認識AIを活用し赤外線サーモグラフィ画像から変状箇所である浮き箇所を簡易かつ客観的に評価する可能性を検討した。その結果、浮き箇所の検出および浮き範囲数値化の可能性が見いだされ、浮きを定量的に評価する手法としての可能性が示唆された。

構築した浮き箇所検出モデルは、画像数および、異なる浮き事例の増加により学習データの幅を広げることで、精度の向上が見込まれる。また、浮き範囲数値化により、浮きの進行度や危険度を評価する新たな指標の検討が可能となった。今後は、検出モデルの改善とともに、浮き範囲の実面積変換、新たな評価指標の検討により、簡易かつ客観的な点検手法の確立を目指したい。

【使用ソフトウェア】

- 1) yolov8, ver8.0.0, Glenn Jocher and Ayush Chaurasia and Jing Qiu, United States, 2023

*1 環境リサーチ

*2 JR 東日本ビルテック

*3 東日本旅客鉄道

*1 Kankyo Research Institute Inc.

*2 JR East, Facility Management Company

*3 East Japan Railway Company