

深層学習によるモルタル吹付けのり面に存在する浮き部の自動検出に関する基礎的分析 —コアサンプリングによる分類性能の検証—

諏訪 太紀¹・藤生 慎²・森崎 裕磨³・福岡 知隆⁴
石塚 久幸⁵・田中 尚人⁶・多田 完人⁷

¹学生会員 金沢大学 大学院自然科学研究科地球社会基盤学専攻 (〒920-1192 石川県金沢市角間町)

E-mail: s.taiki@stu.kanazawa-u.ac.jp

²正会員 金沢大学准教授 融合研究域融合科学系 (〒920-1192 石川県金沢市角間町)

E-mail: fujju@se.kanazawa-u.ac.jp (Corresponding Author)

³学生会員 金沢大学特任助教 融合研究域融合科学系 (〒920-1192 石川県金沢市角間町)

E-mail: yki20@stu.kanazawa-u.ac.jp

⁴正会員 金沢大学博士研究員 融合研究域融合科学系 (〒920-1192 石川県金沢市角間町)

E-mail: tfukuoka@se.kanazawa-u.ac.jp

⁵正会員 株式会社東洋設計 (〒920-0016 石川県金沢市諸江町 212 番地 1)

E-mail: hisayuki.ishizuka@toyosk.co.jp

⁶非会員 協同組合全国企業振興センター (〒920-8203 石川県 金沢市鞍月 4 丁目 24 番地)

E-mail: n-tanaka@jointmaker.com

⁷非会員 協同組合全国企業振興センター (〒920-8203 石川県 金沢市鞍月 4 丁目 24 番地)

E-mail: tada@ikoc.net

モルタル吹き付けのり面は高度経済成長期に多く施工され、現在それらの老朽化が一斉に進んでいる。モルタル吹き付けのり面の変状のうち、浮きについては、目視により確認することは困難であり、打音検査により推定が行われている。しかし、点検技術者の不足、国や地方自治体の財政難などの状況下において、今後打音検査のみによる浮きの診断を継続的に行うことには限界がある。本研究では赤外線画像を用いた深層学習により浮き部の自動検出モデルを二種類構築した。結果として、浮き部周辺の特徴を考慮することが出来る model-2 は浮き部を適切に検出することが可能であり、コアサンプリングの結果から高い精度で損傷を検出することが可能である示唆が得られた。

Key Words: Mortar sprayed cut slope, Deep Learning, thermal image, UAV, Core sampling

1. はじめに

我が国は、山地や丘陵などが国土全体の約 70% を占めている。また、都市は沿岸部に形成される傾向にあり、都市域を結ぶ主要道路をはじめ、道路は急峻な山地や丘陵を通過して供用されることが多く、結果としてのり面が広域かつ多数形成されている。

のり面のうち、切土のり面は、切土直後に安定しているも、多量の降雨、湧水、地震などによって崩壊することがある。これに対して、のり面表層部分の崩壊や風

化を防止する目的で、のり面保護工としての構造物が設置される。

のり面保護工のうちモルタル吹付けのり面は、施工性が良く凹凸のある法面においても施工可能であることから、高度経済成長期とともに 1970 年頃に多く施工された工法であり、現在、これらのモルタル吹付けのり面は施工後 40 年以上が経過し、吹付け面の剥離・剥落及び崩落による災害が発生するなど、老朽化が一斉に進んでいる。モルタル吹付けのり面の維持管理において、変状の把握を行い、それに応じた措置を講じることが重要であり、着目

する変状としては亀裂や剥離、浮き等がある。これらの変状のうち、浮きについては、目視により確認することが困難であり、打音検査により推定が行われている。しかし、我が国における点検技術者の不足(図-1)、国や地方自治体の財政難(図-2)などの状況下²⁾において、打音検査のみによる浮きの診断を継続的に行うことには限界がある。今後、限られた予算や人員の中で、モルタル吹付のり面を適切に維持管理するためには、より効率的な点検手法の確立が必要である。

そこで、本研究では、モルタル吹付のり面の点検の効率化を支援する枠組みとして、浮き部と健全部で表い面温度特性に差が生じる特徴を活用し、赤外線画像を用いた深層学習によるモルタル吹付のり面に存在する浮き部の自動検出システム(図-3)の構築を目指す。本システムは撮影、解析、点検の3フェーズに分かれている。撮影フェーズでは、点検現場にて、点検技術者が赤外線カメラを搭載した UAV により点検対象のり面の撮影を行い、対象のり面の赤外線画像の取得を行う。解析フェーズでは撮影フェーズで取得した赤外線画像の合成を行い、学習済み深層学習モデルによって浮き部が検出された検出結果画像を出力する。最後に、点検フェーズでは、解析フェーズにて出力された検出結果画像より浮き部箇所のスクリーニングを行った上で打音検査を実施し、損傷部の記録を行う。以上のように本システムは、膨大な量の点検対象面から深層学習による浮き部検出結果に基づきスクリーニングを行うことで、点検コストの削減を図るものである。

本研究では、浮き部の自動検出システムに向けて、システム中の解析フェーズに該当する、赤外線画像を用いた深層学習による浮き部の自動検出モデルの構築を行い、その分類性能の評価を行う。

2. 既往研究の整理と本研究の位置づけ

(1) 既往研究の整理

近年、計算機及び深層学習技術の発展により、土木構造物の損傷を画像より分類・判定することが可能になっており、深層学習により損傷の検出を試みた研究は膨大な蓄積がある。

深層学習による構造物の自動検出に関する、代表的な手法として深層学習によるひび割れ検出手法が挙げられ例えば、Cha et al.⁴⁾は、撮影条件による影響を低減させるために画像処理を施した画像を小領域に分割した画像に対し、畳み込みニューラルネットワークによる Deep Learning モデルによってひび割れを含むもの、含まないものの2クラスに分類することで、ひび割れが存在する大まかな範囲を検出可能とした。

南ら⁵⁾は、100メガピクセル(11608×8708px)の超高




図-1 土木職員数の減少⁴⁾

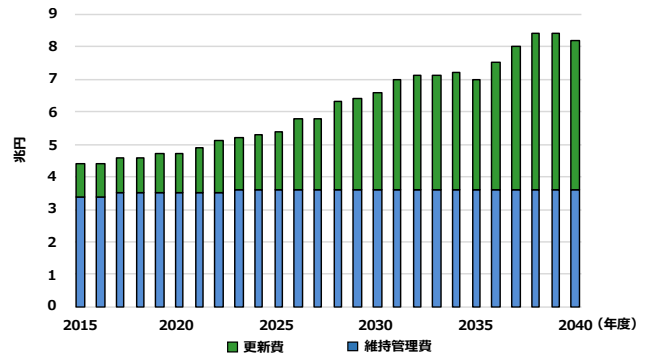


図-2 維持管理費・更新費推移⁴⁾

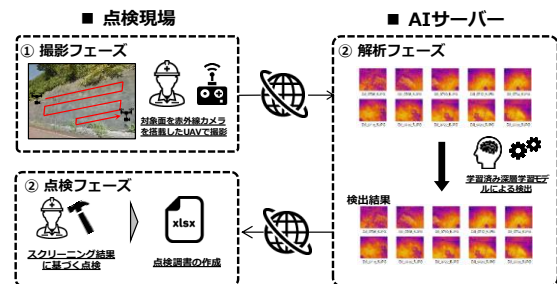


図-3 本研究で提案するシステムの概要

解像度カメラで撮影された広範囲のコンクリート構造物の画像に対してメッシュ分割を行い複数の画像に分割し、各画像を CNN で作成した画像分類器によりひび割れの有無を判定している。また、メッシュ分割の位置を移動した結果を合成し平均をとる Average Shifted Mesh という手法により、ひび割れ箇所の検出精度・出力結果の分解能の向上を図った。

以上のように、点検対象とする構造物に対して、対象領域を小領域に分割し、その小領域の単位で損傷の検出が行われている。しかし、ひび割れは軽微なものであれば非常に細かく、メッシュ単位での判定ではクリティカルな検出が行えない。これに対して、全⁶⁾からは、畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)によるひび割れ箇所のスクリーニングと Random Forest による画素単位の分析を組み合わせた検出手法をしている。また、画像内の全要素に分類クラスのラ

ベル付けを行うことで、画素単位の検出を行う **Semantic Segmentation** を用いたコンクリート表面のひび割れ、P コン跡、型枠跡の画素単位の検出手法を提案している。これらは、損傷の内ひび割れの検出を試みている研究であるが、近年ではその他の損傷についても検出を試みている研究が行われている。

党ら⁷⁸⁾は、UAV で画像の取得を行い、物体検出のための深層学習手法の一つである **YOLO** を用いて、同一画像から複数の損傷（ひび割れ、剥離、腐食）を同時に検出する手法を提案した。CNN による画像分類では学習時にラベル付けを行っていない背景画像を誤認識してしまう傾向にあり、UAV 撮影で取得したデータは損傷個所の割合が少なく、背景や健全な橋梁部材の領域がほとんどであるため特に誤認識が多いが、YOLO では背景の誤認識が半分程度になることが確認されている。

吉倉ら⁹⁾は、橋梁の損傷の内、遊離石灰を対象として、深層学習モデルの構築を行った。また、深層学習による損傷検出結果が、点検診断員が適切に診断できる物であることに重点をおき、画素レベルの検出から 100×100 px 単位の検出まで数段階のサイズで検出を行い、点検診断員を対象としたアンケートを行うことで、検出結果の粗さに対する許容値を検討した。結果として、遊離石灰を囲むチョーキング面積に対する遊離石灰領域面積の比率であるチョーキング内遊離石灰占有率が、70%の検出結果の粗さであれば十分であり、ピクセル単位の検出でなく、メッシュ単位の検出で問題なく、学習データの作成作業にかかる稼働・費用を省力化することで、一定の時間で作成できる学習データが増え、検出モデルの向上につながると述べている。

また、構造物に存在する浮き部について、AI 技術を活用している研究も存在する。例えば、江本¹⁰⁾らは、コンクリート構造物 50 箇所（RC-T 桁やコンクリート壁など、設計基準強度が異なる構造物）を対象として、劣化部と健全部を点検ハンマーにより打音し、打撃点から少し離れた箇所でも打音を録音したものをデータとしている。この打音データに対して、明らかにイオンであったものを欠陥部とみなしてラベリングを行っている。音声データに対して、高速フーリエ変換を行い周波数領域に変換したものを 0 から 20kHz まで 2kHz ごとに振幅スペクトルの総和をとったものを入力として、ニューラルネットワークやランダムフォレスト、サポートベクタマシン、ロジスティック回帰などの機械学習手法で、分類を試みている。結果として、ニューラルネットワークの精度が最も高く有効であることが明らかとなった。また、深層学習手法の一つである自己符号化器（オートエンコーダー）の適用についても検討している。

橋本ら¹¹⁾は、コンクリート構造物の部材厚が均一でないことから生じるコンクリート構造物自体の温度勾配に

よる熱画像への影響を除去するために、対象ピクセルを中心とする任意の範囲の平均温度を移動平均により求め、画像化する熱画像フィルター処理を適用した熱画像に対して、打音点検結果が浮きまたは剥離であるものについては、「要点検」、浮き・剥離以外については「その他」としてラベリングを行い、CNN による二値分類問題として点検要否判別制度を検証している。CNN の学習を行う際にデータ数を均等にならすために、データ数の少ないクラスの画像を反転・回転させ拡張し学習を行い、学習に使用していないデータを用いて検証を行った。しかし、CNN による損傷自動判別の精度向上には限界があると考察しており、温度差領域の特徴を捉え統計的な手法により判別を試みている。具体的には、温度変化グレードを 3 値化させた解析画像を使用し、各損傷の形状を、占有率・複雑度・円形度といった定量的な指標を幾何学的特徴量とし、解析画像を「浮き」、「剥離」、「ノロ」、「異物混入」の 4 クラスに分類する機械学習モデルの構築を行っている。機械学習手法としては、「ニューラルネットワーク」、「ロジスティック回帰」、「判別分析」、「決定木分析」を用いた。結果として決定木分析が最も精度が高く、確信度の閾値を 0.8 に設定した場合に、自動判別と打音点検結果の一致率が 98.0% と高い精度で分類が可能であった。

(2) 本研究の位置付け

前節で示したように近年、公共インフラの維持管理において、UAV によるデータ取得や深層学習手法による変状の自動検出についての研究は膨大な蓄積がある。しかし、深層学習による損傷検出については、ひび割れや遊離石灰、剥離、鋼材の腐食など目視での確認の代替として行われているものがほとんどである。本研究で対象とする損傷である浮きについて、打音データを用いた AI 技術による分類も行われているが、点検の効率化を図るうえでは、非接触による点検が望ましいと考えられ本研究は有用であると言える。また、非接触かつ客観性がある赤外線サーモグラフィ画像と深層学習（CNN）による自動検出も試みられているが、モルタル吹付のり面を対象としたものは存在しない。したがって、モルタル吹付のり面に対して、深層学習により浮き部の検出を試みる点が本研究の新規性であると言える。

3. データ取得方法

本研究では石川県内に点在する吹付のり面の内 4 箇所を対象としてデータの取得を行った。

本研究で使用した機材を図-4 に示す。UAV は DJI の MATRICE200V2¹⁵⁾、赤外線カメラは DJI と FLIR 共同開発の ZenmuseXT¹⁶⁾を使用した。赤外線カメラの主な仕様として、センサーは非冷却 VOx マイクロボロメータ、FPA は 640×512 px、画素ピッチは $17\mu\text{m}$ 、フルフレーム率は 30Hz、温度分解能は $<50\text{mK}$ at $f/1.0$ である。

本研究では、対象物の温度分布を画像として扱うことが可能である赤外線画像を使用する。本研究では、画像認識の手法である CNN によりモデルの構築を行う。CNN では視覚的な情報の特徴として分類を行うが、朝の時間帯及び夕方時間帯に撮影した赤外線画像において画像内の温度差が小さく浮き部と健全部間で視覚的な差が見られなかった。そのため、本研究では赤外線画像内において温度差が大きい昼の時間帯に撮影した赤外線画像 24 枚を教師データとして使用した。また、モデルの学習に当たって赤外線画像内の浮き部の位置を把握しておく必要がある。そこで本研究では、コンクリート診断士による打音検査により、浮き領域の把握を行い、浮き部境界線にアルミニウム板を張り付けることで赤外線画像内において浮きの把握を行った。データ取得時の様子及び赤外線画像における浮き領域の把握例を図-5 に示す。また、本研究で取得した赤外線画像は撮影現場の撮影コンディションにより、撮影距離は 4~10m、空間分解能は 3.58~8.95mm/px の範囲であった。



図-4 撮影に使用した UAV 及び赤外線カメラ




図-5 打音検査の様子及び浮き部の推定例




図-6 CNN の一般的な構成

4. 浮き部自動検出モデルの作成

本研究では、深層学習の手法の一つで、画像認識に利用されている畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) により、モデルを構築する。本章では、CNN の概要、作成したモデルの概要を述べる。

(1) CNN 概要

CNN は、中間層に畳み込み層とプーリング層の 2 種類の層を持つことに特徴がある。特徴量を事前に決定するのではなく、学習を通して、分類において特徴を自動抽出することが可能である。CNN の一般的な構成を図-6 に示す。

CNN による画像認識では始めに入力層に画像を入力し、続いて畳み込み層及びプーリング層で計算が行われ、出力層において分類結果が出力される。

畳み込み層では与えられた入力に対して複数のフィルターで畳み込み演算を行い、特徴マップを生成する。層が深くなるにつれ、線や点などの低次元な特徴から、複雑な高次元の特徴を学習する。

プーリング層は一般的に畳み込み層の直後に配置され、

入力データを扱いやすい形に変形するために、情報を圧縮しダウンサンプリングする。具体的には入力データを小領域に分割し、各領域から代表値をとる演算が行われる。これにより、微小な位置変化に対して頑健となる、過学習が抑制されるといった効果が期待できる。

全結合層では、以前の層までで処理が行われた入力データを一次元に展開し、全結合層における入力および出力の全ユニットを重み付きで結合する。

出力層では、本研究で用いる二値分類の場合、ユニット数は 1 つとなる。結果はシグモイド関数により片方のクラスの尤度として出力される。これにより、尤度の大きいクラスが予測クラスとして出力される。

(2) CNN の学習

CNN モデルを構築する際には、畳み込み層やプーリング層等の中間層の数やそれらのパラメータを設定する必要がある。そこで、本研究では画像認識の分野で高い性能を発揮しており、一般公開されている CNN モデルである VGG16¹⁷⁾を基本構造とし、入力層の形状や分類器の役割を担う全結合層、出力層を変更したものを使用した。

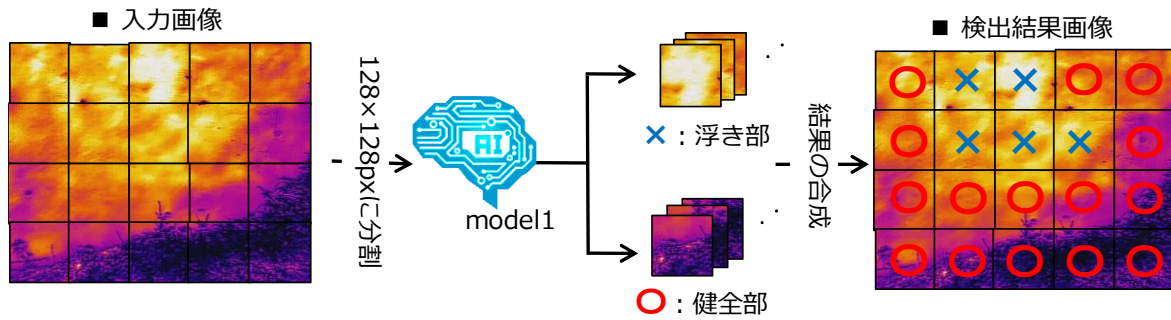


図-7 model-1のイメージ

この他にも、同様に ResNet50¹⁸⁾を基本構造としたモデルを用いて検討したが、VGG16の方が分類性能が高かったため、これを採用した。CNNの学習については、ImageNetで学習済みの重みは使用せず、ネットワークにおけるすべての重みを再学習させた。また、学習の指標となる損失関数には二値交差エントロピーを用い、これを最小化するための最適化アルゴリズムには確率的勾配降下法を用いた。また、最適化の際のパラメータとして、学習率を0.01、momentumを0.9、バッチサイズを16に設定し、100epoch繰り返し学習を行った。また、本研究では、膨大な量の学習データを用意することが出来なかったため、学習時、学習データにオープンソースライブラリであるKerasのImageDataGeneratorを用いてデータ拡張を実施した。本研究では、データ拡張として拡大縮小及び上下左右方向の平行移動を学習が繰り返される毎にランダムに適用した。

(2) 浮き部検出モデルの作成

本研究では、浮き部の自動検出モデルとして、入力される赤外線画像に対して128×128pxで分割された領域単位で判定を行うモデル(model-1)を構築した。model-1のイメージを図-7に示す。学習データとしては、取得した赤外線画像を128px×128pxに分割し、それらに「浮きあり」、「浮きなし」の2クラスの正解ラベルを与えたものを使用した。この時、正解ラベルはアルミ反射板で囲まれた領域内を「浮きあり」、それ以外を「浮きなし」としている。また、本研究で作成した検出モデルは浮きの有無を出力する2値分類であるため、各クラスの画像枚数に偏りがあると、すべての画像を画像枚数が多いクラスに分類すれば、見かけ上の精度が高くなるため、2つのクラス間における決定的な特徴量を学習するのではなく、見かけ上の精度が向上するような方向に学習を行う可能性が懸念される。そこで、本研究では2つのクラスのうち画像枚数の少ないクラスの画像を時計回りに90°、180°回転させることで、2つのクラスの画像枚数の

偏りを軽減した。これらの手順により、本研究では、学習用データを138枚によりモデルの学習を行った。

(3) 浮き部検出モデルの評価

本研究では、学習に用いていない赤外線画像2枚を用いて、モデルの汎化性能の評価を行う。

モデルの分類性能を評価するために、混合行列を作成し、正しく分類できた件数、誤って分類した件数を集計する。本研究における真陽性(TP: True-Positive)は「浮き部を分類モデルが浮き部であると正しく判定できた件数」、真陰性(TN: True-Negative)は「浮き部でない箇所を分類モデルが浮き部でない箇所であると正しく判定できた件数」、偽陽性(FP: False-Positive)は「浮き部でない箇所を分類モデルが浮き部であると判定した件数」、偽陰性(FN: False-Negative)は「浮き部である箇所を分類モデルが浮き部でない箇所と判定した件数」とした。各モデルにおける分類性能の評価指標として再現率(Recall)及び適合率(Precision)を用いる。再現率(Recall)及び適合率(Precision)の算出方法を式(1)、(2)に示す。

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

$$Precision = \frac{TP}{TN + FP} \quad (2)$$

再現率(Recall)は実際に浮き部である箇所を分類モデルが正しく浮き部であると判定した割合を示すもので、分類における見逃しの少なさを指標である。適合率(Precision)は分類モデルが浮き部であると判定した件数のうち実際に浮き部であった割合を示すものであり、過検出の指標である。また、正解率(Accuracy)については赤外線画像内において浮き部の箇所が少なく、データに偏りがあり評価に適していないと判断したため本研究では用いていない。作成したモデルにおける検出結果及び再現率、適合率を表-1に示す。表-1においてモデル

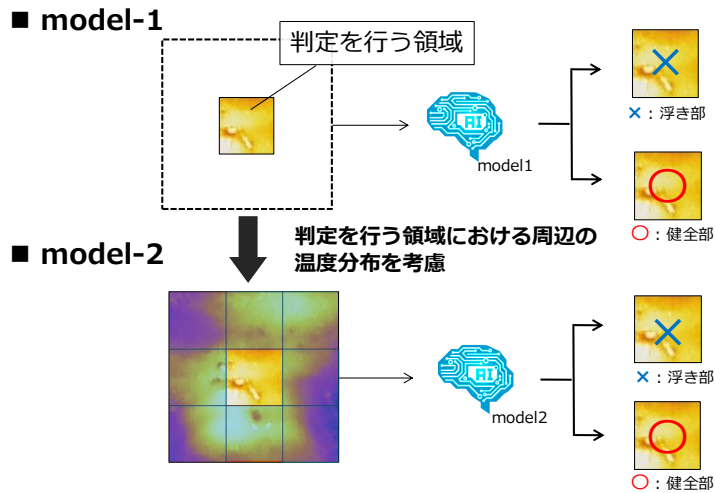


図-8 model-2のイメージ

表-1 model-1における検出結果及び評価値

画像	画像1	画像2
検出結果		
評価	適合率：0.67 再現率：1.00	適合率：0.00 再現率：0.00

表-2 model-2における検出結果及び評価値

画像	画像1	画像2
検出結果		
評価	適合率：0.80 再現率：1.00	適合率：1.00 再現率：0.17

が浮き部であると推定した箇所については青いバツ印が表示されている。また、白いハッチングがされている領域は打音検査により浮きが確認された箇所である。検出結果より、作成したモデルは赤外線画像内において温度の高い領域を浮き部であると判定していると考えられる。しかし、何らかの要因で浮き部でないのにも関わらず温度の高い領域が含まれる場合に、温度の高低のみで浮き部を判定することは困難である。そこで、本研究では、温度の高低でなく、浮き部における周辺の温度分布を考慮したモデルを作成した。モデルの詳細については次章で述べる。

64px分を黒い画像で補完している。この画像を図-9に示すように、左上より192×192pxで切り出し、次に64pxだけ右にずらし、192×192pxで切り出す。これを画像右端まで行い、その後下方向に対しても同様に切り取りを行う。この手順によって、1枚の赤外線画像より80枚の学習データが得られる。これにより、学習用データとして1494枚の赤外線画像が得られた。なお、データ作成時には背景等の関係のない箇所は取り除いている。また、これらの学習データの正解ラベル付けは、切り取った画像中心部64×64pxの領域がアルミ反射板で囲まれた領域である場合「浮きあり」、それ以外を「浮きなし」として行った。

5. 浮き部周辺の特徴を考慮した検出モデル

(1) 浮き部周辺の特徴を考慮した検出モデルの概要

浮き部周辺の特徴を考慮した検出モデルの手法のイメージを図-8に示す。

前章で述べたモデルが評価領域に対して、特徴抽出領域のサイズが等しいのに対して、本モデルは特徴抽出領域として評価領域より広い範囲を学習させた。図-8に示すように、本モデルでは、評価対象領域(64×64px)に接する8領域(192×192px)を特徴抽出領域とした。また、画像端部の評価を行うために画像端部よりそれぞれ

(2) 浮き部周辺の特徴を考慮した検出モデルの評価

本稿4章3節と同様に、検出モデルの評価を行う。検出結果及び適合率、再現率を表-2に示す。検出結果より、浮き部周辺の特徴を考慮した検出モデルは浮き部を適切に検出できていると言える。表-1より、浮き部周辺の特徴を考慮していないモデルでは、温度の高い箇所を浮き部であると推定しているのに対し、浮き部周辺の特徴を考慮したモデルでは単に温度が高い箇所を浮き部であると推定していない。このことから、浮き部周辺の特徴を考慮することで、浮き部を適切に検出できることが可能である示唆が得られた。

6. コアサンプリングによるモデルの検証

(1) コアサンプリングの結果

本研究では、モルタル吹付のり面に存在する浮き部の自動検出モデルとして model-1 と model-2 を作成した。作成した検出モデルは打音検査により推定された浮き部を教師データとして使用している。本研究では、検出モデルのうち、model-2 により、調査対象としたモルタル吹付のり面に対して、取得した赤外線画像を解析し、解析結果より浮き部と判定した箇所と判定されなかった箇所に対してコアサンプリングを行うことで、model-2 による真の浮き部に対する検出能力の検証を行う。コアサンプリングはモデルが浮き部と判定した箇所 26 箇所、判定されなかった箇所 4 箇所の合計 30 箇所を対象とした。

コアサンプリングの結果より、コアサンプリング箇所において、図-9 に示す通り、空洞化、モルタルの脆性化、モルタルの二層化、健全部の計 4 種類の性状が確認された。本研究では、健全部を除いた性状をモルタル吹付のり面の損傷と定義する。




図-9 コアサンプリングにより確認された変状

表-3 コアサンプリング結果に基づく混合行列

		正解クラス	
		浮きあり	浮きなし
予測クラス	浮きあり	TP (15)	FP (11)
	浮きなし	FN (0)	TN (4)

表-4 model-2 における浮き部の検出性能

評価指標	model-2 における浮き部の検出性能
再現率 (Recall)	1.00
適合率 (Precision)	0.58
陰性的中率 (NPV)	1.00
F値 (F-measure)	0.73

(2) model-2 における浮き部の検出性能

コアサンプリング調査によって、得られた結果をもとに Precision, Recall に加えて、陰性と判定された個所のうち、実際に陰性であった割合である NPV (Negative Predictive Value) と再現率と適合率の調和平均である F-measure により評価を行う。F-measure は以下に示す式(3)で表される。また、本研究において NPV は検出モデルが浮き部でないと判定した箇所が実際に浮き部でなかった割合のことであり、以下の式(4)で表される。コアサンプリング調査の結果より得られた混合行列を表-3 に示す。この際、二層化とモルタル吹付の脆性化については、浮きなしとしている。混合行列より、算出した性能評価指標を表-4 に示す。表-4 より model-2 における浮き部の検出性能としては、再現率が 1.00 であり、見逃しのないモデルであると言える。しかし、適合率は 0.58 程度であることから、浮き部を過検出している傾向にあると考えられる。これは、脆性化と二層化を浮き部であると判定していることが原因である。

$$F - measure = \frac{2Recall \cdot Precision}{Recall + Precision} \quad (3)$$

$$NPV = \frac{TN}{TN + FN} \quad (4)$$

(3) model-2 における損傷の検出性能

本研究では浮き部の検出モデルをコンクリート診断士による打音検査により推定した浮き部領域を学習させ

ることで作成した。コアサンプリング調査から、浮き部以外にも、モルタルの脆性化と二層化が表面温度を相対的に高くする要因であることが明らかとなった。また、打音検査による浮き部の推定により、浮き部のみを誤る事なく推定するのは困難であり、上述した損傷が教師データに含まれていることは十分考えられる。以上より、本研究で作成した検出モデルは、浮き部に加えて、モルタル吹付の脆性化と二層化を検出することが可能である示唆が得られた。

本節では、model-2 がモルタル吹付の脆性化と二層化を含む損傷をどの程度検出することが可能であるかについて、表-5 に示す混合行列にもとづき定量的に評価を行う。また、コアサンプリングの結果が浮き、脆性化、二層化のどれかである場合に、損傷あり、健全部であった場合に損傷なしとする。

表-5 に示す混合行列によって算出したモルタル吹付のり面における損傷の検出性能の評価値を表-6 に示す。表-6 より、再現率 (Recall) および陰性的中率 (NPV) は 1.00 であり、見逃しがなく、適合率 (Precision) が 0.92 であり、コアサンプリングを行った 30 箇所に対して過検出箇所が 2 か所のみと、非常に高い精度で損傷の検出を行うことが可能であるという示唆が得られた。

7. まとめと今後の課題

(1) 本研究のまとめ

本研究では、モルタル吹付のり面の浮き部の自動検出システムの構築に向けて、赤外線画像と深層学習を組み合わせた浮き部の自動検出モデルを作成した。検出モデルとして、model-1 と model-2 の二種類のモデルを作成し、結果として、判定領域周辺の温度分布を考慮する model-2 の方が浮き部を適切に検出することが可能であった。また、コアサンプリング調査の結果から浮き部、モルタルの脆性化、モルタルの二層化、健全部の計 4 種類の性状が確認された。本研究で使用した教師データにおける浮き部は、打音検査により推定された箇所であり実際にはその他の損傷が含まれていることが考えられる。本研究では、確認された 3 つの変状を損傷と定義し、モデルの検証を行った。結果として、再現率および陰性的中率は 1.00 であり、見逃しが無く、コアサンプリングを行った 30 箇所に対して過検出箇所が 2 か所のみと、非常に高い精度で損傷の検出を行うことが可能であるという示唆が得られた。

(2) 今後の課題

本研究では作成した浮き部の自動検出モデルのうち、浮き部を適切に検出することが可能である model-2 について、コアサンプリングの結果に基づき検証を行った。結果として、浮き部以外に、モルタル吹付本体の脆性化、二層化が表面温度を相対的に高くする要因であり、model-2 が浮き部であると誤判定する要因であることが明らかとなった。打音検査による浮き部の推定により、浮き部のみを誤ることなく推定するのは困難であり、上述した損傷が教師データに含まれていることは十分考えられる。コアサンプリングを継続的に行うことで、温度分布と背面の性状が紐づけられたデータの蓄積を行うことで損傷の種類別の分類を行うことが可能になると考えられる。また、本研究ではモルタル吹付のり面に存在する浮き部の自動検出システムのうち、深層学習による浮き部の検出モデルの構築のみを行った。システムにおける点検フェーズにおいて、スクリーニングを行うことで点検時間がどの程度削減されるかが、本システムの有用性を担保する上で重要であり、今後取り組むべき内容である。

参考文献

- 1) 補強土工法研究会 老朽化吹付のり面補修工：
<http://www.japan-hokyoudo.jp/roukyuuka-morutaru.html>
(2022 年 1 月 25 日閲覧)
- 2) 国土交通省：社会資本の適確な維持管理・更新，<http://w>

表-5 コアサンプリング結果に基づく損傷の検出性能に関する混合行列

		正解クラス	
		損傷あり	損傷なし
予測クラス	損傷あり	TP (24)	FP (2)
	損傷なし	FN (0)	TN (4)

表-6 model-2における損傷の検出性能

評価指標	model-2における損傷の検出性能
再現率 (Recall)	1.00
適合率 (Precision)	0.92
陰性的中率 (NPV)	1.00
F値 (F-measure)	0.96

www.mlit.go.jp/hakusyo/mlit/h23/hakusho/h24/html/n1216000.html
(2022 年 1 月 25 日閲覧)

- 3) 国土交通省：社会インフラの維持管理の動向，<http://www.mlit.go.jp/hakusyo/mlit/h25/hakusho/h26/html/n1133000.html> (2022 年 2 月 10 日閲覧)
- 4) Cha, Y., Choi, W. and Büyüköztürk, O.: Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks, *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361-378, 2017.
- 5) 南貴大, 福岡知隆, 藤生慎, 寒河江雅彦: Average Shifted Mesh を用いたひび割れ箇所自動検出の分解能・精度向上に関する分析, *AI・データサイエンス論文集*, pp.473-480, 2020
- 6) 全邦釘, 嶋本ゆり, 大窪和明, 三輪知寛, 大賀水田生: ディープラーニング及び Random Forest によるコンクリートのひび割れ自動検出, *土木学会構造工学論文集 A*, Vol.73, No.2, pp.297-307, 2017.
- 7) 山根達郎, 全邦釘: Deep Learning による Semantic Segmentation を用いたコンクリート表面ひび割れの検出, *構造工学論文集 A*, Vol.65A, pp.130-138, 2019.
- 8) 党紀, 水元大雅, 全邦釘, 刘佳明, 藤嶋斗南: YOLO を用いた多種類橋梁損傷の同時検出, *AI・データサイエンス論文集*, pp.447-456, 2021.
- 9) 田畑佑, 党紀, 春田大二郎, Ashish SHRESTHA, 松永昭吾, 全邦釘: UAV 撮影と深層学習を用いた橋梁損傷の自動検知に関する検証, *土木学会論文集 F4 (建設マネジメント)*, Vol.74, No.2, pp.I_62-I_74, 2018.
- 10) 吉倉麻衣, 南貴大, 福岡知隆, 藤生慎, 高山純一: 深層学習を用いた遊離石灰の自動検出と結果表示サイズに関する橋梁技術者の評価, *AI・データサイエンス論文集*, pp.29-36, 2020
- 11) 江本久雄, 馬場那仰, 浅野寛元, 長瀬大和: AI 手法による打音検査の浮き判定の検討, *AI・データサイエンス論*

- 文集, pp514-521, 2020
- 12) 橋本和明, 林詳悟, 明石行雄: 赤外線サーモグラフィ法の技術的な問題点と画像処理技術の研究, コンクリート構造物の非破壊検査論文集, Vol.4, pp.389-398, 2012.
- 13) 林詳悟, 橋本和明, 明石行雄: 赤外線サーモグラフィ法によるコンクリートの検出精度向上, コンクリート工学年次論文報告集, Vol.35, pp.1813-1818, 2013.
- 14) 川西弘一, 林詳悟, 橋本和明, 氏家勲, 全邦釘: 赤外線サーモグラフィ法における損傷自動判別分析, AI・データサイエンス論文集, pp382-391, 2020
- 15) DJI HP : <https://www.dji.com/jp/matrice-200-series-v2> (最終閲覧日: 2022年2月25日)
- 16) FLIR HP(Zemuse XT2) : <https://www.dji.com/jp/zenmuse-xt2> (最終閲覧日: 2022年2月25日)
- 17) K. Simonyan and A.Zisserman. Very deep convolutional networks for large-scale image recognition. In Proc.3rd ICLR,2015
- 18) Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun : Deep Residual Learning for Image Recognition, arXiv preprint arXiv:1512.03385, 2015

**FUNDAMENTAL ANALYSIS OF AUTOMATIC DETECTION OF VOIDS AREAS
ON MORTAR SPRAYED SLOPES USING DEEP LEARNING
: EVALUATION OF CLASSIFICATION PERFORMANCE BY CORE SAMPLING**

Taiki SUWA, Makoto FUJIU Yuma MORISAKI, Tomotaka FUKUOKA,
Hisayuki ISHIDUKA, Naohito TANAKA, and Naruhito TADA

Mortar-sprayed slopes were constructed in large numbers during the high-growth period of the Japanese economy, and now they are all deteriorating at the same time. Among the deformations of sprayed mortar surfaces, voids are difficult to confirm visually, and are estimated by acoustic inspection. However, the shortage of inspection technicians and the financial difficulties of national and local governments have limited the ability to continue to diagnose floating structures solely by acoustic inspection in the future. In this study, two types of models for automatic detection of voids areas were constructed by deep learning using thermal images. The results show that model-2, which can take into account features around the floating area, is capable of detecting voids areas appropriately, and the core sampling results suggest that it can detect damage with high accuracy.