

【建設工学研究所論文報告集第62号〔論文〕2020年11月】

機械学習によるコンクリート橋点検写真のひび割れ分類における 要因分析と効率化に関する基礎的研究

Fundamental Study on Efficiency Analysis for Classification of Digital Photographs in Concrete Bridges Inspection by means of Machine Learning

三木 朋 広 笹 脇 壮 太
Tomohiro Miki Sota Sasawaki

1. 研究背景と目的

人工知能（AI）とは、人間が行う活動の一部を、コンピュータープログラムを用いて人工的に再現したもの、もしくはその研究分野を指す。中でも近年注目を集めている機械学習は、データの背後に潜む規則性や特異性を発見することにより、人間と同程度あるいはそれ以上の学習能力をコンピューターで実現しようとする技術である。これを用いると、過去の事例・観測データからの学習に基づき、モノやコトの判別・分類、予測、異常検知などの知的な判断をコンピューターで実現可能となる。

高度成長期以降に整備された道路橋、トンネル、河川、下水道、港湾などについて、今後数十年で建設後50年以上経過する施設の割合が加速的に高くなる。国土交通白書¹⁾によると、建築後50年以上経過する道路橋（橋長2m以上の橋）の割合は、2018年3月では約25%であるのに対し、2023年3月には約39%、2033年3月には約63%と増加する。こうした劣化した道路橋を含めたコンクリート構造物の健全度は、作業員が現地に出向き、破損箇所を手持のデジタルカメラ等で撮影し、図-1.1に例示するような点検調書²⁾をもとにして判定される。点検調書においては、橋梁の健全度の判定に必要な情報、特に各部位における損傷を写真、ならびに例えばコンクリートのひび割れであれば発生箇所やひび割れ長さ、密度、ひび割れ幅などの情報が、点検者の所見とともに示されている。これらは構造物の維持管理における重要な情報であり、そのような情報が蓄積されつつある状況にある。

しかし、経年劣化に対応するために必要な資金と専門知識を有する人材の不足が、大きな社会問題となっている。この問題を解決するために、点検の現状を踏まえて、筆者らはコンクリートの点検写真のデータ整理を機械学習によって行い、将来的に高速化・自動化・無人化に向けた検討を行っている。本稿では、特定の橋梁において点検写真のひび割れやチョーキングの画像を損傷の程度等でグループ分けをする、もしくは異なる橋梁における同程度のひび割れ等の写真を効率よく収集するためのツールの作成を試みるものである。本研究では基礎検討としてひび割れ写真の分類に焦点を当てた。



図-1.1 点検調書²⁾

ここで、機械学習では、教師データとなる写真とその分類の正解を与え、その結果を基に分類していくが、その過程がブラックボックス状態であるため、本稿では、様々な要因の感度について傾向分析を行う。そのために、コンクリートひび割れを模した線画像の分類を想定される条件で解析し、その特徴を考察した。今回の研究で得られた結果、考察をもとに、最終の目標である「機械学習を用いて道路橋の画像データからひび割れがある画像を自動で分類する技術」へ向けた展開に関する課題抽出を行うことを目的とした。

2. 解析手法

2. 1 解析アルゴリズムの概要

ひび割れを模した線画像の分類をするにあたり、分類結果とその精度に与える影響感度を検討するため、Pythonによって実装化したScikit-learn³⁾のLinear Support Vector Classification(Liner SVC)を用いて分類器を作成した。その際、各解析ケースにおける正答率、適合率、再現率を指標にして考察した。

ここで、Scikit-learnは、プログラミング言語Pythonを用いた機械学習において、予測データ分析を行うシンプルなオープンソースのアルゴリズムである。また、その中でLinear-SVC⁴⁾を用いることによって、複数クラス分類を実行できる。この手法を用いることによって、分類、回帰、外れ値の検出について、教師あり学習によってパターン認識が可能となる。例えば、画像をA、Bの項目に分けることを考える場合、A、Bのそれぞれの特徴のうち、色、大きさ、長さなど定量的に扱えることができる α 個の特徴量に着目すると、画像の特徴は特徴空間と呼ばれる α 次元空間の1点として表現することができる。この α 次元ベクトル(特徴ベクトル)について、学習用画像から得られるパターンを不明なパターンのクラスを判定する識別規則を学習パターンによって求めることがSVMの役割である。また、SVMは、線形分離可能な場合、不可能な場合の両方に適応可能なパターン認識手法であり、複数の識別境界候補の中でマージンを最大にする超平面を最適解として算出する。しかし、簡便な分類手法ではあるが、分類に必要な特徴量が不明確であり、いわゆるブラックボックスとなるといった課題がある。

2. 2 解析結果の評価指標

本研究で用いる分類器の性能を評価するにあたり、正答率、適合率、再現率の3つの指標で評価した。表-2.1に予測結果と正解の組合せである混同行列を示す。式(1)~式(3)に示す各指標の定義は以下のとおりである。つまり、正答率は全予測に対する正答率のことをいい、基本的にはこの値によって、分類器の性能を評価する。また、適合率は正と予測したデータのうち、実際に正であるものの割合のことであり、適合率重視の例として、迷惑メール判定を行う際、迷惑メールが迷惑と判定されなくて(FN)もいいため、通常メールを迷惑判定(FP)したくないような場合である。さらに、再現率は実際に正であるもののうち、正であると予測されたものの割合である。再現率重視の例として、工場の不良品の検知が挙げられる。この場合は、不良品の見落とし(FN)がないことを目標とするので、多少の健全のものを不良品と判断してもいいことになる。

同様に本研究で実施する多クラス分類(項目を0, 1, 2とする)は、表-2.2ならびに式(4)~式(6)で表される。

表-2.1 混同行列

	実際は正 (Positive)	実際は負 (Negative)
予測が正 (positive)	True Positive (TP)	False Positive (FP)
予測が負 (Negative)	False Negative (FN)	True Negative (TN)

$$\text{正答率 (Accuracy)} = \frac{TP+TN}{TP+FP+FN+TN} \quad (1)$$

$$\text{適合率 (Precision)} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{再現率 (Recall)} = \frac{TP}{TP+FN} \quad (3)$$

表-2. 2 多クラスの場合の混同行列

	実際は 0	実際は 1	実際は 2
予測が 0	True 0	False 0(1)	False 0(2)
予測が 1	False 1(0)	True 1	False 1(2)
予測が 2	False 2(0)	False 2(1)	True 2

$$\text{全体の正答率} = \frac{\text{True 0} + \text{True 1} + \text{True 2}}{\text{True 0} + \text{True 1} + \text{True 2} + \text{False 0} + \text{False 1} + \text{False 2}} \quad (4)$$

$$0 \text{ の適合率} = \frac{\text{True 0}}{\text{True 0} + \text{False 0}} \quad (5)$$

$$0 \text{ の再現率} = \frac{\text{True 0}}{\text{True 0} + \text{False 1(0)} + \text{False 2(0)}} \quad (6)$$

3. 線画像の分類の解析

3. 1 画像データ

ひび割れを模した線画像をパソコン内に入っているペイントツールを使って作成した。線は基本的に黒ではあるが、カラー画像を使用し、線画像が分類できるかどうかにはフォーカスするため、背景は無地の白にした。

なお、作成したデータは、以下の形式に統一した。




- ・サイズ：40px×40px（ペイントツールで769px×614pxのサイズで画像作成後、40px×40pxに変換）
- ・画像：24bit カラー
- ・ファイル形式：PNG

3. 2 分類項目の設定

線画像の分類については、3種類とし、それぞれラベルとして0, 1, 2の番号を付した。それぞれの判定基準は線の本数でクラス分けを行った。ラベル名、条件、画像例を表-3. 1に示す。なお、論文中で示す各画像には黒枠を付けているが、解析においてはこの枠線はなく、白背景としている。また、今回の解析にあたり、以下の出力を設定した¹⁾。

- ・教師用データの読み込み時間の測定
- ・正答率と各ラベルの適合率、再現率の表示

表-3. 1 ラベル名、条件、画像例

ラベル名	0	1	2
条件（線の本数）	0本	1～5本	6本以上
画像例		 <p>R 0, G 0, B 0, 色合い 160, 明るさ 0, 鮮やかさ 0</p>	 <p>R 0, G 0, B 0, 色合い 160, 明るさ 0, 鮮やかさ 0</p>

3. 3 教師データ数による比較

3. 3. 1 解析概要（解析1～4）

まず、0, 1, 2の3種類の画像ファイル（できるだけ傾向が偏らないように無造作に書いた）がそれぞれ15枚ずつ入れたフォルダ4個（フォルダ名をそれぞれNo. 1, No. 2, No. 3, No. 4とする）と100枚ずつ入れたフォルダ1個（フォルダ名をNo. 5とする）を用意した。フォルダNo. 1～No. 5すべてにおいて、769×614pxの白紙に、3pxの太さ、三原色をR（赤）0, G（緑）0, B（青）0の配分、色合い160, 明るさ0, 鮮やかさ0の黒色で描いた後、40×40pxのサイズに変換した。解析ケースを表-3. 2にまとめる。解析1～解析4では、フォルダNo. 1をテストデータとし、教師データとなるフォルダをNo. 2, 3, 4, 5と徐々に増やしながら、解析を行うことによって、データ数による正答率、適合率、再現率、教師データの読み込みの時間の比較を行った。各解析はそれぞれ10回行った。

表-3. 2 解析1～4の概要

解析ケース	テストデータ (フォルダ名)	教師データ (フォルダ)	テストデータ 枚数	教師データ 枚数
解析1	No. 1	No. 2	45	45
解析2	No. 1	No. 2, 3	45	90
解析3	No. 1	No. 2, 3, 4	45	135
解析4	No. 1	No. 2, 3, 4, 5	45	435

3. 3. 2 解析結果と考察

解析1～4の正答率についてみると、図-3. 1から教師データ数が多ければ多いほど正答率の平均値は上昇することがわかる。またデータのばらつきも小さくなる傾向が観測された。一方、適合率については、図-3. 2からラベル0, ラベル1に関して、教師データの量と適合率に正の相関がみられた。ラベル2についても解析1をのぞき、適合率は上昇しているといえる。解析1のラベル0の適合率の平均値は解析2～4より高くなってはいるが、データのばらつきが大きいため正確な値とはいえない。また、データのばらつきはラベル0を除いて、データの量に伴い、小さくなることがわかった。

再現率については、図-3. 3からラベル0においては常に1.0の値を示していることがわかる。ラベル1, 2は多少の誤差はあるものの、教師データ数の増加に伴い再現率は上昇していることがわかる。しかし、データのばらつきは解析3のラベル2では極めて小さいが、その他では教師データの増加に伴い減少する傾向ではなく、拡大したケースもみられた。また、ラベル0は再現率が常に1.0であることから、実際にラベル0であるもののうちラベル0であると完全に予測されているが、ラベル0に分類された画像には、ラベル1, またはラベル2の画像も混入していた。ただし、教師データ数の増加にしたがって適合率は上昇しているため、ラベルごとの誤った分類については減少する傾向があることもわかる。

データの読み込み時間については、図-3. 4をみると各解析においてデータのばらつきがなく、正の相関がみられた。データの読み込みに必要な時間を y (sec)とし、教師データ数を x (枚)とすると、式(7)のような1次関数になる。

$$y = 0.06667x + 3.0 \quad (7)$$

ここで、 x : 教師データ数 (枚), y : データ読み込み時間 (sec)




図-3.1 解析1~4の正答率




図-3.2 解析1~4の適合率




図-3.3 解析1~4の再現率




図-3.4 解析1~4の教師データの読み込み時間

3.4 テストデータが特定条件の場合の比較

3.4.1 解析概要 (解析5~7)

実際のコンクリート橋に発生するひび割れは、線の太さ、深さ（色合い）、形状は様々である。また、写真画像では、背景の明るさ、ひび割れが発生した材質も異なっている。こうした状況の中で、正常に分類できるかを先ほどの線画像の分類にできるだけ当てはめて検証した。まず前出のフォルダ No.1~5 と同様の条件下で作成したフォルダ No.6 を用意し、各ラベルの画像をそれぞれ 10 枚準備した。その後、フォルダ No.6 の線配置と同じ画像データを各ラベル 10 枚ずつ作成し、それぞれ No.6-1, No.6-2, No.6-3 とした。この3個のフォルダ内の画像を、線の色、背景の色、線の太さを変更し、テストデータとして使用した。教師データはフォルダ No.6 とし、評価指標は正答率、教師データの読み込み時間とする。各解析はそれぞれ 10 回行った。各解析ケースは表-3.3の通りである。

表-3.3 解析5~7の概要

解析ケース	テストデータ (フォルダ名)	教師データ (フォルダ名)	検討項目とテストデータ、教師データの特徴
解析5	No.6-1	No.6	検討項目：線の色 No.6：黒色 (R 0, G 0, B 0, 色合い 160, 明るさ 0, 鮮やかさ 0) No.6-1：灰色 (R 192, G 192, B 192, 色合い 160, 明るさ 181, 鮮やかさ 0)
解析6	No.6-2	No.6	検討項目：背景の色 No.6：黒色 (R 0, G 0, B 0, 色合い 160, 明るさ 0, 鮮やかさ 0) No.6-2：灰色 (R 192, G 192, B 192, 色合い 160, 明るさ 181, 鮮やかさ 0)
解析7	No.6-3	No.6	検討項目：線の太さ No.6：3px No.6-3：8px

3. 4. 2 解析結果と考察

テストデータと教師データの線の配置は変わっていないので、条件を変えずにテストデータをフォルダ No. 6, 教師データを No. 6 とすると正答率は 1.0 となる。しかし、図-3. 5 から解析 5 の正答率が低いことがわかった。解析 6 は 1.0 に近い値が計測され、解析 7 は試行した 10 回すべて 1.0 の値が計測された。このことより、線画像の分類において、テストデータと教師データの線の色の違いが正答率に大きな影響を与えることがわかった。なお、正答率が 1.0 の場合が多いので（正答率が 1.0 の場合、適合率、再現率はどちらも 1.0 となるので）今回は、適合率、再現率は計測しない。また、線の色による適合率、再現率の考察は次節で行う。教師データの読み込み時間においては平均時間 5.26 秒であったので、式(7)の関係がおおよそ成り立つことがわかった。




図-3. 5 解析 5~7 の正答率

3. 5 テストデータにおける線の色の違いによる比較

3. 5. 1 解析概要（解析 8~10）

前節における検討結果より、色の違いが正答率に影響することを確認した。ここでは線の濃淡に注目してより詳しく調べた。教師データとテストデータの濃淡の差が正答率に与える影響を検討するため、テストデータの線の色の値を教師データの線の黒色から段階的に違いを大きくする（薄くする）よう変化させて、比較検証を行った。解析ケースを表-3. 4に示す。フォルダ No. 6 の線配置を変えず 3 種類の色が異なる画像データを各ラベル 10 枚ずつ準備し、これらをフォルダ No. 6-4, No. 6-5, No. 6-6 とした。教師データをフォルダ No. 6 とし、テストデータをフォルダ No. 6-4, No. 6-5, No. 6-6 でそれぞれ解析を行い、評価指標として正答率、適合率、再現率を算出した。各解析はそれぞれ 10 回行った。

表 3. 4 解析 8~10 の概要

解析ケース	テストデータ (フォルダ名)	教師データ (フォルダ名)	検討項目とテストデータの特徴
			No. 6 : 黒色 (R 0, G 0, B 0, 色合い 160, 明るさ 0, 鮮やかさ 0)
解析 8	No. 6-4	No. 6	検討項目 : 色の濃淡 (濃淡の差 小) No. 6-4 : 各 R, G, B 80, 色合い 160, 鮮やかさ 0, 明るさ 76
解析 9	No. 6-5	No. 6	検討項目 : 色の濃淡 (濃淡の差 中) No. 6-5 : 各 R, G, B 160, 色合い 160, 鮮やかさ 0, 明るさ 151
解析 10	No. 6-6	No. 6	検討項目 : 色の濃淡 (濃淡の差 大) No. 6-6 : 各 R, G, B 240, 色合い 160, 鮮やかさ 0, 明るさ 226

3. 5. 2 解析結果と考察

図-3. 6 をみると、色が薄くなるにつれて正答率が低下することがわかる。解析 8, 9, 10 の順番でデータのばらつきも次第に大きくなり、正確性が減少した。図-3. 7, 図-3. 8 からラベル 0 においては色が薄くなると、適合率は減少し、再現率は 1.0 を維持していることがわかる。つまり確実にラベル 0 をラベル 0 と分類しているが、色が薄くなるにしたがってラベル 1, 2 をラベル 0 と判断した結果が多くなっている。ラベル 1, ラベル 2 に関する適合率は解析 8, 9 においては 1.0 の値を維持していたが、解析 10 になると大幅に減少した。またデータのばらつきも突然大きくなった。またラベル 1, 2 における再現率は色が薄くなるにしたがって、徐々に低下する傾向がみられた。




図-3. 6 解析 8~10 の正答率




図-3. 7 解析 8~10 の適合率




図-3. 8 解析 8~10 の再現率

3. 6 教師データの線の色の違いによる比較

3. 6. 1 解析概要 (解析 11~14)

3. 4では教師データを固定してテストデータの線の違いで解析を行ったが、実際に存在するひび割れ画像を教師データにすると、線の色が均一ではないことが想定される。そこで、教師データに様々な色の線画像を入れた場合を検討した。解析ケースを表-3. 5に示す。テストデータをフォルダNo. 6-1とし、教師データをフォルダNo. 6, No. 6-4, No. 6-5, No. 6-6の組合せとした。評価指標は前と同様に正答率, 適合率, 再現率とした。また、各解析はそれぞれ10回行った。

表-3. 5 解析 11~14 の概要

解析ケース	テストデータ (フォルダ名)	教師データ (フォルダ名)
解析 11	No. 6-1	No. 6-6
解析 12	No. 6-1	No. 6-5, 6-6
解析 13	No. 6-1	No. 6-4, 6-5, 6-6
解析 14	No. 6-1	No. 6, 6-4, 6-5, 6-6

3. 6. 2 解析結果と考察

図-3. 9より教師データに線の色の特徴を増やすと、正答率が上昇するとともに、結果のばらつきが小さくなることがわかった。図-3. 10, 図-3. 11より教師データに線の色の特徴を増やすと、正答率同様、適合率, 再現率が上昇する。特にラベル2の適合率, 再現率は1.0の値をとるケースが多くみられた。これはラベル2と予測されたものがすべてラベル2であること, テストデータのラベル2がすべてラベル2であると予測されたということを意味する。図-3. 12をみると教師データを読み込んだ時間はこれまでの解析通り, 式(7)に従うこともわかる。




図-3. 9 解析 11~14 の正答率




図-3. 10 解析 11~14 の適合率




図-3. 11 解析 11~14 の再現率




図-3. 12 解析 11~14 の教師データ読み込み時間

4. HOG を用いた解析

4. 1 HOG 特徴量

3. 5 ならびに 3. 6 の結果から線の濃淡による正答率の低下が明らかとなった。この原因は分類器が線の形状に加え、線の濃淡を特徴量と判断し、分類したためと推察する。そこで、線の濃淡に違いが見られる画像群の分類において、線の濃淡ではなく、線の形状のみを捉える分類に関する検討を行った。その際、HOG 特徴量に着目した。ここで、HOG (Histogram of Oriented Gradients) 特徴量とは、1つの局所領域内におけるエッジ方向ごとのエッジ強度に着目した特徴量である。この画像におけるエッジは、画像内における物体や文字等の輪郭を捉えたものであり、画像中にある物体の形状を表わすものである。画像認識における局所領域はブロックとして表現され、各ブロックは複数のセルと呼ばれるさらに小さな局所領域から構成される。そのため HOG 特徴量は、セルのエッジ方向毎のエッジ強度ヒストグラムを結合した多次元ベクトルで表現される。この「ピクセル毎の輝度の変化の方向と強さ」を「セル単位でヒストグラム化」した後「ブロック単位で正規化」することにより、HOG 特徴量を算出することができる。

また、HOG 特徴量は、複数のセル内に含まれる勾配方向ごとの情報を特徴量とする高次元特徴量である。つまり、HOG 特徴量を使うことで物体の境界に関する情報を取り出しやすくなる。輝度の変化量を基準とするため、明るさの変化に強い、局所的な幾何学的変化に強いといった利点がある。今回は、エッジ方向を9方向とし、3600次元のベクトルとして、計算する。線画像の HOG 特徴量を可視化した結果を図-4. 1 に例示する。

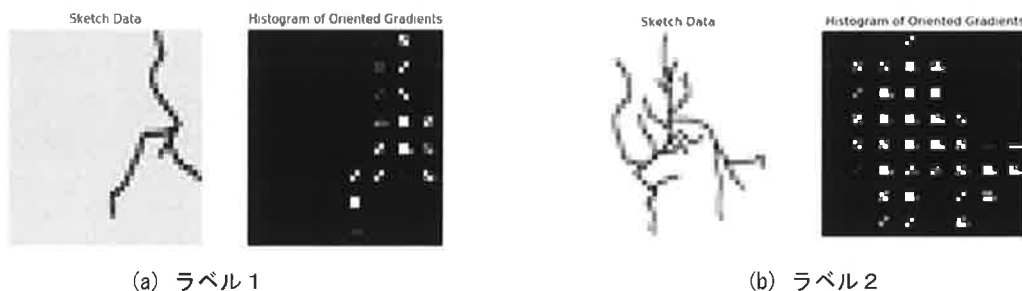


図-4. 1 各ラベルの画像と HOG 特徴の画像の比較

4. 2 HOG 特徴量を用いた解析の概要

解析 4. 8, 9, 10 について、HOG 特徴量を用いて再度解析を行った。それぞれ、教師データについては各ラベル 145 枚、合計 435 枚、テストデータについては各ラベル 15 枚、合計 45 枚の画像データを準備した。評価指標は正答率、適合率、再現率、教師データの読み込み時間とする。また、前解析と同様に各解析はそれぞれ 10 回行った。

4. 3 解析結果と考察

解析 4 を HOG 計算して同様の解析を行うと、図-4. 2～図-4. 5 の結果が得られた。図-4. 2 より正答率が上昇し、図-4. 3, 図-4. 4 からは、適合率、再現率ともに上昇し、ラベルごとの分類の精度が向上したことを確認できる。また、図-4. 5 からは教師データの読み込み時間が短縮したことがわかる。435 枚の教師データを処理する場合、画像をそのまま教師データに入れるより 6 分の 1 の時間で処理できることを確認した。すべての評価指標でデータのばらつきがみられず、試行回数 10 回すべてにおいて同じ値が計測された。このことにより、特徴量を絞った場合、信頼性の高い解析が可能になる。また、実際のコンクリートひび割れの分類においては、ひび割れの濃淡に影響されずに、形状のみを分類することが可能になると考える。

解析 8, 9, 10 についても HOG 処理後に同じ解析を行うと、正答率、適合率、再現率がいずれも 1.0 となることがわかっている。つまり、線の色を輝度の勾配方向をヒストグラム化したものに置き換えると、フォルダ No. 6-4, No. 6-5, No. 6-6 の HOG 処理後の画像がすべて同じものと認識されて、分類機能の低下を克服できることがわかった。




図-4.2 HOG 計算の正答率




図-4.3 HOG 計算の適合率




図-4.4 HOG 計算の再現率




図-4.5 HOG 計算の教師データの読み込み時間

5. 結論

本研究では、PythonによるScikit-learnのLinear Support Vector Classification(Liner SVC)を用いて、コンクリート橋のひび割れを模した線画像のクラス分類を行った。機械学習による分類の影響感度を分析し、可視化することを試みた。また、線の色の違いが分類の精度に影響するため、HOG 計算処理による解析精度の向上を試みた。本研究で得られた成果は以下のとおりである。

- (1) 教師データ数について検討した解析 1~4 によって、教師データ量が大きくなると正答率が高くなり、データのばらつきが小さくなることがわかった。教師データ数と教師データの読み込み時間は1次関数で評価できる。
- (2) テストデータの影響を調べた解析 5~7 によって、テストデータの線の色、背景の色、線の太さを教師データの画像と異なるもので解析すると、線の色が異なる場合のみ大幅な正答率の低下がみられた。
- (3) 解析 8~10 によって、テストデータの線の色の配合が教師データの線の色の配合から離れるごとに分類の精度が低下することを確認した。
- (4) テストデータに未知の線の色が出てきた場合、解析 11~14 の検討結果から、教師データの線の色の特徴量を増やすと正答率が向上することがわかった。
- (5) HOG 計算処理を行うと、解析 8~10 の正答率がすべて 1.0 になったことから、線の色のばらつきを統一することができたといえる。解析 4 においても正答率が向上し、データのばらつきもみられなかった。また、HOG 計算処理により、教師データの読み込み時間も短縮され、精度が高く効率の良い分類が可能となることがわかった。

今後の課題として、以下の点が挙げられる。

- (1) Scikit-learn を使ったひび割れの分類では、背景の色、線の太さの要因の違いは特に影響しないことを確認したが、線の濃淡の違いによる正答率の低下がみられたことから、実際の点検画像の分類に採用する場合、ひび割れの深さによる色の濃淡やエフロレンスなどを識別できない可能性が考えられる。
- (2) HOG 特徴量を用いることによって、線の形状を抽出して分類することで正答率の精度を上げることに成功したが、実際の点検写真への適用を想定する場合、線の形状による分類では十分ではない。システム開発では、今回考慮しなかったエフロレンスなどひび割れ以外の要因の影響を把握する必要がある。

謝 辞

本研究の一部は、令和1年度建設工学研究所一般研究助成によって実施した。ここに感謝の意を表する。

参 考 文 献

- 1) 国土交通省：橋梁定期点検要領，2019.3
- 2) 国土交通省：令和2年版国土交通白書 <https://www.mlit.go.jp/statistics/file000004.html> (2020.9.18 確認)
- 3) 前田英作：痛快！サポートベクトルマシン -古くて新しいパターン認識手法-，情報処理，42(7)，676-683，2001
- 4) 鶴 英雄ほか：Pythonによる機械学習入門，オーム社，2016

著 者

三木 朋広 研究員，博士（工学），コンクリート構造
笹脇 壮太 神戸大学大学院生，学士（工学）