

論文 光条件を考慮した深層学習による舗装ひび割れの検出に関する研究

田中 熙*¹・柴野 一真*¹・鈴木 哲也*²

要旨：コンクリート構造物の維持管理において、構造物表面の画像からひび割れを検出する深層学習手法による点検の自動化が試みられている。舗装のひび割れを AI により検出するうえで、本研究で対象とした橋梁の舗装は日向部と日陰部で明度が異なり検出精度に差がある。本研究では、深層学習モデルに学習させる画像を光条件ごとに分類するシーン分類を行い、路面部の各光条件に対応するひび割れ検出モデルの作成を試みた。検討の結果、ひび割れを日向路面部、日陰路面部を別々のモデルで検出させた場合の F 値は本研究での最大値である 0.778 を示し、データセットの質が検出精度に影響を及ぼす可能性が示唆された。

キーワード：データ拡張, LeNet, U-Net, 画像処理, シーン分類

1. はじめに

近年、道路橋の経年劣化に対する対応策が課題となっている。日本では、2023 年時点で全橋梁の約 37 % が建設から 50 年以上経過しており、2033 年には約 61 % に増加すると推測されている¹⁾。橋梁の高齢化は今後急速に進んでいくと予想され、維持管理のためには定期的な点検が必要である。これまで、構造物表面の損傷度を把握する点検手法は目視による実施が基本だった²⁾。目視による点検は専門的な知識を有する技術者によって行われる必要があるが、現状では目視点検により適切に維持管理がなされているとはいえない。その要因として、目視点検は主観的判断に頼らざるを得ないという点検手法自体が抱える課題に加え、技術者の減少および予算の不足に起因する点検数の不足が挙げられる³⁾。これらの問題を解消すべく、AI や IoT を代表とするデジタル技術を活用した自動化が推進されている⁴⁾。本研究のテーマである深層学習により構造物表面の画像からひび割れを検出する手法についても、これまでに様々な検出手法が提案されている⁴⁾。

機械学習や深層学習で扱うモデルには、データセットとして学習させる画像を入力する必要がある。モデルに入力するデータセットは量と質が出力の精度に影響を与えることが知られている⁵⁾。データセットの量に関して、データ量が多くなるほどモデルの汎用性は向上する。逆に、データ量が少なくなるほど過学習する可能性が大きくなる。データセットの量が少ない場合、画像処理によるデータ拡張が有効であることが示されている。ひび割れの検出においては、ひび割れを含んだ実際の画像に処理を加えて人工的なひび割れ画像を生成するデータ拡張が試みられている⁶⁾。データセットの質に関して、入力する画像がノイズを多く含んでいる場合、モデルが学習対象の特徴を正確に捉えられない場合がある。画像処理

手法はノイズの除去やエッジの強調のように画像の特徴を強調させることができるため、データセットの質を向上させるための手法としても適用されている⁷⁾。

本研究では、橋梁の舗装のひび割れを対象に、UAV に搭載された可視カメラによって撮影を行った。計測時の橋梁の舗装において、日射が届いている日向路面部と日射が障害物に遮られた日陰路面部が確認された。日向と日陰は明度が異なる⁸⁾ため、ひび割れの検出精度が異なっていた。そこで本研究では、日向路面部と日陰路面部のひび割れの検出精度を向上させるため、取得した画像をノイズ部、日向路面部、日陰路面部に分類するシーン分類モデルを作成し、日向路面部のみ、日陰路面部のみを学習させたひび割れ検出モデルを作成した。シーン分類モデルとひび割れ検出モデルの構築には、深層学習のアーキテクチャである LeNet, U-Net を用いた。シーン分類モデルの分類精度、ひび割れ検出モデルの検出精度を検証するとともに、ひび割れ検出モデルのデータセットがひび割れの検出精度に及ぼす影響を考察する。

2. 対象構造物および計測方法

2.1 対象構造物

計測対象は、新潟県柏崎市で供用されている橋梁の清水谷大橋、前川原橋、桧倉大橋の舗装部である。可視画像の取得について、日向路面部と日陰路面部を明確に判別するため、天気が晴れ、舗装部が乾燥している状況下で計測した。各橋の舗装部の損傷はそれぞれで異なっている。目視観察の結果、3 橋の舗装のいずれもひび割れに代表される損傷が確認された。日向路面部の損傷はすべての橋梁で確認され、日陰路面部の損傷は清水谷大橋でのみ確認された。

2.2 計測方法

本研究では、清水谷大橋、前川原橋での計測を UAV の

*1 新潟大学大学院 自然科学研究科 (学生会員)

*2 新潟大学 自然科学系 (農学部) 博士 (工学) (正会員)

Matrice 210 (DJI 社) に搭載されたデジタルカメラの Zenmuse XT2 (FLIR Systems 社) により行った。カメラの技術仕様について、焦点距離は 8 mm、画像幅の画素数は 4,000×3,000 pixels およびセンサーサイズは 7.5×5.6 mm である。栃倉大橋での計測は、UAV の Matrice 350 RTK (DJI 社) に搭載されたデジタルカメラの Zenmuse L1 (FLIR Systems 社) により行った。カメラの技術仕様について、焦点距離は 8.8 mm、画像幅の画素数は 5,472×3,648 pixels およびセンサーサイズは 13.2×8.8 mm である。オートフォーカスは用いず、一定の間隔で撮影を行った。ひび割れの解像度を一定に保ちながら幅員が画角に収まるようにするため、UAV は高度を離陸地点から 5 m 一定に保つよう調整して飛行させた。地上画素寸法 (以下、GSD と示す) は、デジタルカメラの技術仕様および UAV の高度の関係によって決定される⁹⁾。清水谷大橋、前川原橋での計測時の GSD は 0.12 cm/pixel であり、栃倉大橋での計測時の GSD は 0.14 cm/pixel だった。GSD の導出式を式(1)に示す。

$$GSD = \frac{H \times \frac{SW}{ImW}}{F} \times 100 \quad (1)$$

ここで、 H は UAV の高度 (m)、 SW はセンサーサイズ (mm)、 ImW は画像サイズ (pixel)、 F は焦点距離 (mm) である。GSD は 1 ピクセルに写る地表の実際の長さを表す数値であり、ひび割れの検出においては画像からひび割れ幅を特定するための指標となる。

3. 解析方法

3.1 解析概要

本研究で構築を試みたひび割れの検出フローを図-1に示す。UAV によって撮影された元画像は、128×128 pixels の解析画像に分割される。各解析画像はシーン分類モデルによってノイズ部、日向路面部、日陰路面部に分類される。ノイズ部は、植生や欄干、白線等画像中に路面以外の物体が少しでも写っている画像と定義した。日向路面部、日陰路面部に分類された画像は、それぞれ

の路面画像に適したひび割れ検出モデルによってひび割れの有無が各ピクセルに対し判定される。ひび割れ検出モデルとして、日向路面部、日陰路面部ごとにひび割れを学習させたモデルを作成した。モデルの精度を検証するため、日向路面部と日陰路面部の両方のひび割れを学習させたモデルを作成した。結果では、シーン分類モデルおよびひび割れ検出モデルの精度を評価する。

3.2 データセット

シーン分類モデルのデータセットを作成するため、解析画像を目視によりノイズ部、日向路面部、日陰路面部に分類した。日向部と日陰部が混在した路面部は、それぞれの割合が大きいものを日向路面部、日陰路面部として筆者らにより目視で分類した。ノイズ部の画像は 3,119 枚、日向路面部の画像は 1,691 枚、日陰路面部の画像は 537 枚用意した。モデルに学習させるため、各条件の画像の 8 割を学習データとして使用した。モデルの精度を検証するため、2 割をテストデータとして使用した。画像の分割は無作為に行った。

ひび割れ検出モデルで用いるデータセットの正解画像として、ひび割れを含んでいた日向路面部、日陰路面部の画像に対しアノテーションを行った。アノテーションにより、画像の各ピクセルにはひび割れ部もしくは非ひび割れ部に属しているかという情報が付与される。アノテーションは、アノテーションソフトウェアである Fast Label を用いて行った。各正解画像は日向路面部の画像で 1,312 枚、日陰路面部の画像で 130 枚、合計 1,442 枚用意した。日陰路面モデルのデータセットは、日向路面モデルのデータセットと比較して 1/10 程度である。画像解析の精度はデータセットの量と質に影響されるため、データセットの質を検証するためには量を統一する必要がある。そこで、日陰路面モデルのデータセットの量を増強するデータ拡張を行い、日陰路面部の画像を疑似的に 1,312 枚、合計 2,624 枚まで増強した。ひび割れ検出では、学習させるデータセットの質およびデータ拡張の効果について検証する。ひび割れ検出モデルは日向路面モ




図-1 ひび割れの検出フロー

デル、データ拡張前の日陰路面モデル、データ拡張後の日陰路面モデル、日向路面部と日陰路面部の両方である路面全体を学習させたモデル（以下、路面全体モデルと示す）の計4つのモデルを作成した。ひび割れ検出モデルでは、ハイパーパラメータチューニングを行う。ハイパーパラメータチューニングの検証用データおよび学習データとして画像の8割を使用し、テストデータとして残りの2割を使用した。U-Netのデータセットの分割においてもLeNetと同様に無作為に行った。

3.3 データ拡張


日陰路面モデルのデータ拡張として、従来手法である左右反転に加え、画像処理によって日向路面部の画像を日陰路面部の画像に近似させる手法を採用した。526枚の、学習データに用いる日向路面部に対し画像処理を行い、日陰路面部と合わせた合計656枚を左右反転させることにより1,312枚に増強した。画像処理は画像の $L^*a^*b^*$ 色空間を対象に行った。明度は L^* で表される。 L^* が大きいほど明るく、 L^* が小さいほど暗くなる。色相と彩度は a^* と b^* で表され、値は色の方向を示す。 a^* は+が赤方向、-が緑方向を表し、 b^* は+が黄方向、-が青方向を表す。値によって彩度に変化し、絶対値が大きくなるほど鮮やかになる。 $L^*a^*b^*$ 色空間において、陰は L^* と b^* の値に影響を及ぼすことが知られている⁸⁾。

清水谷大橋の日向路面部および日陰路面部の画像から取得した L^* の分布を図-2に示す。横軸は各 L^* の値、縦軸は頻度を表す。路面画像の L^* は広範囲に分布しており、特にひび割れは相対的に小さい値に分布している。日向路面部を日陰路面部に近似させる画像処理を行うにあたって、各ピクセルの L^* を一律に小さくする手法はひび割れと路面部の L^* のコントラストが無くなる可能性がある。そこで、 L^* に対しては区分線形補間による画像処理を行った。区分線形補間は、画像から陰を除去するための手法として試みられている¹⁰⁾が、本研究では陰を生成するための手法として用いた。区分線形補間では、入力画像と目標画像の L^* が指定した区間幅で取得され、入力画像の L^* が同じ区間の目標画像の L^* に置換される。区分線形補間の式(2)を以下に示す。


$$y = y_i + \frac{y_{i+1} - y_i}{x_{i+1} - x_i} (x - x_i) \quad (2)$$

ここで、 y は出力画像の各ピクセルの L^* 、 x は入力画像の各ピクセルの L^* 、 y_i 、 x_i は区間の開始点の L^* 、 y_{i+1} 、 x_{i+1} は区間の終了点の L^* である。2点間は線的に補間され、入力画像の各 L^* は決まった値で出力される。本研究では、この区間幅を5%に設定して区分線形補間を行った。

清水谷大橋の日向路面部および日陰路面部の画像から取得した a^* 、 b^* の分布について、日向路面部および日陰路面部で特に差が確認された b^* の分布を図-3に示す。




(a) 清水谷大橋日向路面部の L^*




(b) 清水谷大橋日陰路面部の L^*

図-2 L^* のヒストグラム



(a) 清水谷大橋日向路面部の b^*



(b) 清水谷大橋日陰路面部の b^*

図-3 b^* のヒストグラム

L^* と比較して、狭い範囲に分布していることが確認された。そこで、 a^* と b^* に対してはレベルシフトを用いた。レベルシフトの式(3)を以下に示す。

$$y = x + (G_m - x_m) \quad (3)$$

ここで、 y は出力画像の各ピクセルの a^* および b^* 、 x は入力画像の各ピクセルの a^* および b^* 、 G_m は目標画像の a^* および b^* の最頻値、 x_m は入力画像の a^* および b^* の最頻

値である。入力画像の a^* と b^* の最頻値が、目標である日陰路面部の画像の最頻値と同一になるように各ピクセルの値を一律に調整するようにした。 a^* 、 b^* のヒストグラムは狭い範囲で分布しているため、区分離線補間を使わなくてもレベルシフトにより入力画像の a^* と b^* の分布傾向を変えずに推移させることができる。

3.4 モデルのアーキテクチャ

シーン分類モデルのアーキテクチャに採用した LeNet は、画像認識分野において高い性能を発揮している CNN の一種である。CNN は、畳み込み層とプーリング層、全結合層によって構成される。畳み込み層では、入力画像の局所的な特徴が抽出され、特徴マップとして再構成される。プーリング層では、抽出された特徴の抽象性が増し、位置情報のずれに対する頑健性が獲得される。CNN では、畳み込み層とプーリング層が交互に繰り返されることで入力画像の抽象的な特徴が学習される。全結合層では、畳み込み層とプーリング層の繰り返しによって得られた大量の特徴の次元が一次元に集約される。その集約された特徴をもとに、出力層によってノイズ部、日向路面部、日陰路面部のいずれかに分類される。バッチサイズを 32、最大のエポック数を 50、最適化手法を Adam、活性化関数を ReLU 関数に設定して学習を行った。

ひび割れ検出モデルのアーキテクチャに採用した U-Net は、FCN をベースに構築された。U-Net は、左右対称になっているエンコーダとデコーダの各層が、スキップ接続によって繋がることで構成される。エンコーダでは畳み込みとプーリングが繰り返され、位置情報のずれに頑健かつ局所的な特徴が抽出される。デコーダはスキップ接続によって同階層のエンコーダと繋がっており、詳細な位置情報が復元される。U-Net は特徴の詳細な位置情報を保持できるため、ピクセル単位の検出が可能となっている。ひび割れ検出モデルは、ハイパーパラメータチューニングによるハイパーパラメータの最適化を行った。モデルごとに、カーネルサイズ (3, 5, 7) とバッチサイズ (8, 16) に対してチューニングを試行回数 20 回で実施し、最も損失が少なかった各ハイパーパラメータを採用した。その他のパラメータについて、最大のエポック数を 100、損失関数をバイナリークロスエントロピー、最適化手法を Adam、活性化関数は中間層で ReLU 関数、出力層でシグモイド関数に設定して学習を行った。

3.5 評価指標

シーン分類モデルの分類精度は、正解率により評価する。正解率を求める式(4)を以下に示す。

$$\text{正解率} = \frac{T}{T+F} \quad (4)$$

ここで、 T は正しく分類された画像の枚数、 F は間違っ

てデータに対して分類を行い、分類の正解率を求める。

ひび割れ検出モデルの検出精度は、混同行列に基づいた評価指標である、適合率、再現率および F 値により評価する。各評価指標を求める式(5), (6), (7)を以下に示す。

$$\text{適合率} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{再現率} = \frac{TP}{TP+FN} \quad (6)$$

$$F \text{ 値} = \frac{TP}{TP + \frac{1}{2}(FP+FN)} \quad (7)$$

ここで、 TP (True Positive)はひび割れと判定し、正解だったピクセルの数、 FP (False Positive)はひび割れと判定し、不正解だったピクセルの数、 FN (False Negative)は非ひび割れと判定し、不正解だったピクセルの数である。適合率はひび割れの誤検出の割合を表し、値が大きいほど誤検出が少ないことを示す。再現率はひび割れの未検出の割合を表し、値が大きいほど未検出が少ないことを示す。 F 値は適合率と再現率の調和平均である。本研究では、 F 値が高いモデルほどひび割れを正確に検出できているものとして扱い評価を行った。

4. 結果および考察

4.1 シーン分類モデルの精度評価

シーン分類モデルのテストデータに対する分類結果を表-1、図-4 に示す。表-1 は分類予測の正解数および不正解数を示した混同行列である。1,070 枚のテストデータに対して分類を行い、予測全体の正解率は 94.4%と高水準の結果を得ることができた。その中でも、日向路面部と日陰路面部の分類は特に高精度に行われ、日陰路面部に対しては誤分類なく行われた。大多数の画像は正しく分類されたが、ノイズ部に対して計 56 枚、日向路面部に対して 4 枚の誤分類が確認された。図-4 は誤って分類された事例を示したものである。不正解画像の左側 3 枚は、ノイズ部に属する画像が日向路面部もしくは日陰路面部と誤分類された結果である。シーン分類モデルに

表-1 シーン分類モデルの混同行列

テストデータ : 1,070	分類結果		
	ノイズ	日向路面部	日陰路面部
正解率 : 94.4%			
ノイズ	568	45	11
正解ラベル 日向路面部	4	335	0
日陰路面部	0	0	107



図-4 シーン分類モデルの誤分類事例

は、ノイズ部として植生や欄干、白線等多様な物体が写っている画像を学習させた。その影響によりモデルがノイズ部の特徴を捉えきれず、結果として路面部の特徴と合致している可能性が高いと誤分類した可能性が考えられる。右端の画像は、日向路面部に属する画像がノイズ部と誤分類された結果である。画像には、他の路面部の画像と比較して相対的にひび割れ部が多く含まれていた。このひび割れ部をノイズ部と誤分類したことによる結果だと考えられる。このような誤分類は、ひび割れ部を多く含んだ路面部の画像を多く学習させることで少なくできると考えられる。

4.2 日射を考慮したひび割れ検出モデルの精度評価

ハイパーパラメータチューニングの結果を表-2 に示す。データ拡張後の日陰路面モデルで 250.81 と最も小さい損失が、データ拡張前の日陰路面モデルで 437.63 と最も大きい損失が確認された。各ひび割れ検出モデルにおける、各路面部に対するひび割れの検出結果を表-3 に示す。日向路面部に対する検出について、F 値は日向路面モデルの 0.775 という結果に対し、路面全体モデルは 0.772 と殆ど差のない値が確認されたが、日陰路面モデルは 0.737 と若干小さい値が確認された。この検出精度の低下は日向路面部を学習させていないことが原因だと考えられる。

日陰路面部に対する検出について、データ拡張前の日陰路面モデルは適合率を除いた評価指標において最も小さい値が確認された。特に、再現率に関しては他のモデルと 2 倍以上離れた 0.162 となった。データ拡張前の日陰路面モデルはひび割れを検出するための再現率が著しく低いと推察される。一方、データ拡張後の日陰路面部は全ての評価指標において最も大きい値が確認された。データ拡張を行ったことにより、少量だったデータセットが増強され、検出精度が向上したと考えられる。F 値について、日向路面モデルの値は 0.522 であり、データ拡張前の日陰路面モデルを除いた他のモデルの F 値と比較して 0.2 程度小さい値が確認された。日向路面部に対する検出と同様に、日陰路面部の学習の有無が関連していると考えられるが、F 値の減少幅は日向路面部よりも大きくなっている。日陰路面部は日向路面部よりもひび割れ部と路面部の L^* のコントラストが小さいため区別がしにくく、検出の難度が大きい。F 値減少幅の差は、検出難度の差によるものだと考えられる。

路面全体に対する検出結果について、従来のモデルの検出結果に加え、日向路面部に対しては日向路面モデルによる検出を、日陰路面部に対しては日陰路面モデルによる検出（以下、日向路面&日陰路面モデルと示す）を行った結果を示す。適合率は、日向路面&日陰路面モデルで 0.853 と最も大きい値が確認された。再現率は、路面

全体モデルで 0.725 と最も大きい値が確認された。日向路面&日陰路面モデルはひび割れの誤検出において少ない傾向にあり、路面全体モデルはひび割れの未検出において少ない傾向にあると推察される。F 値において、日向路面&日陰路面モデルで 0.778 と最も大きい値が確認された。図-5 に、各路面部に対するひび割れの検出事例を示す。表-3 と同様に、日向路面部に対しては日向路面モデルが、日陰路面部に対してはデータ拡張後の日陰路面モデルにおいて高精度な検出が行われた。

以上の結果から、ひび割れ検出モデルに学習させる路面部の条件を限定させることにより、適合率、F 値が向上する可能性が示唆された。また、データ拡張によるデータセットの増強は、検出精度の向上に寄与する可能性が示唆された。本研究で提案した手法により、データセットの質はモデルの学習条件を限定させることで改善され、データセットの量はデータ拡張により改善される。深層学習によるひび割れの検出において、モデルに入力するデータセットの量および質を改善することは、検出精度の向上において有用であると考えられる。

表-2 ハイパーパラメータチューニングの結果

モデル名	カーネル サイズ	バッチ サイズ	損失
日向路面モデル	16	7	344.69
日陰路面モデル（拡張前）	8	3	437.63
日陰路面モデル（拡張後）	8	7	250.81
路面全体モデル	8	7	365.06

表-3 各路面部に対するひび割れ検出結果の比較

対象：日向路面部	適合率	再現率	F 値
日向路面モデル	0.864	0.703	0.775
日陰路面モデル（拡張前）	0.814	0.241	0.372
日陰路面モデル（拡張後）	0.840	0.657	0.737
路面全体モデル	0.806	0.740	0.772
対象：日陰路面部	適合率	再現率	F 値
日向路面モデル	0.604	0.460	0.522
日陰路面モデル（拡張前）	0.615	0.162	0.256
日陰路面モデル（拡張後）	0.840	0.732	0.782
路面全体モデル	0.728	0.714	0.721
対象：路面全体	適合率	再現率	F 値
日向路面モデル	0.756	0.598	0.668
日陰路面モデル（拡張前）	0.734	0.207	0.323
日陰路面モデル（拡張後）	0.840	0.689	0.757
路面全体モデル	0.771	0.729	0.749
日向路面&日陰路面モデル	0.853	0.715	0.778

5. おわりに

本研究では、UAVによって撮影された橋梁の舗装画像に対し、深層学習によってシーン分類とひび割れの検出を行った。シーン分類では可視画像をノイズ部、日向路面部、日陰路面部に分類することを試みた。ひび割れの検出では、日向路面部、日陰路面部のみを学習させたひび割れ検出モデルを作成し、各路面部に対応するモデルによってひび割れを検出させることを試みた。本研究で明らかになった事項を以下にまとめる。

- (1) シーン分類は94.4%の正解率が確認されたが、ノイズ部の分類では誤分類が多く確認された。モデルが路面部の特徴をより学習するようにし、ノイズ部と路面部の違いを強調する必要がある。
- (2) 日陰路面部は、データ拡張によりF値が大きく改善された。L*に対しては区分線形補間を、a*とb*に対してはレベルシフトを行うことで光条件を統一するデータ拡張手法が有効に働いたと考えられる。
- (3) 日向路面部に対しては日向路面モデルによるひび割れの検出で、日陰路面部に対してはデータ拡張後の日陰路面モデルによる検出で最も大きいF値が確認された。モデルの学習条件を限定させることによりデータセットの質は改善され、高精度なひび割れの検出が行われるようになると考えられる。

謝辞

橋梁での計測には新潟県農地部の協力を得た。ここに記して感謝申し上げる。

参考文献

- 1) インフラ健康診断書 2024, 土木学会 : https://committees.jsce.or.jp/reportcard/system/files/JSC_E_Report_Card_2024.pdf (閲覧日: 2025年1月7日)
- 2) 老朽化対策の取組, 国土交通省 : <https://www.mlit.go.jp/road/sisaku/yobohozen/torikumi.pdf> (閲覧日: 2024年12月18日)
- 3) Hoang, N.D., Nguyen, Q.L. and Tran, V.D.: Automatic recognition of asphalt pavement cracks using metaheuristic optimized edge detection algorithms and convolution neural network, Automation in Construction, Vol.94, 203213, Oct. 2018
- 4) Kheradmandi, N. and Mehranfar, V.: A critical review and comparative study on image segmentation-based techniques for pavement crack detection, Construction and Building Materials, Vol.321, 126162, Feb. 2022
- 5) Krizhevsky, A., Sutskever, I. and Hinton, G.E.: ImageNet Classification with Deep Convolutional Neural Networks, Communications of the ACM, Vol.60, No.6, pp. 84-90,




図-5 各路面部に対するひび割れ検出の事例

May. 2017

- 6) Nguyen, T.S., Begot, S., Duculty, F. and Avila, M.: Free-form Anisotropy: A New Method for Crack Detection on Pavement Surface Images, 18th IEEE International Conference on Image Processing, pp. 1069-1072, Sep. 2011
- 7) 島本由麻, 鈴木哲也: 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, Vol.91, No.1, pp. 69-76, 2023. 3
- 8) Murali, S. and Govindan, V.K.: Shadow Detection and Removal from a Single Image Using LAB Color Space, Cybernetics and Information Technologies, Vol.13, No.1, pp. 95-103, Mar. 2013
- 9) 作業規程の準則 第 420 条, 国土交通省 : <https://www.gsi.go.jp/common/000258734.pdf> (閲覧日: 2024年12月3日)
- 10) Liu, W. and Yamazaki, F.: Object-Based Shadow Extraction and Correction of High-Resolution Optical Satellite Images, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol.5, No.4, pp. 1296-1302, Aug. 2012