

深層学習による微地形表現図に基づく 道路斜面災害リスク箇所抽出モデルの構築

MODEL FOR IDENTIFYING HIGH RISK SLOPES ALONG ROADS
BASED ON MICROTOPOGRAPHY MAPS USING DEEP LEARNING

伊藤 真一¹・西村 修一²・上原 大二郎³・王寺 秀介⁴・酒匂 一成⁵
Shinichi ITO, Shuichi NISHIMURA, Daijiro UEHARA, Shusuke OJI, and Kazunari SAKO

¹立命館大学 理工学部 環境都市工学科 (〒525-8577 滋賀県草津市野路東 1-1-1)

E-mail: sito@fc.ritsumei.ac.jp

²中央開発株式会社 東京支社 (〒169-8612 東京都新宿区西早稲田 3-13-5)

E-mail: nishimura@ckcnet.co.jp

³中央開発株式会社 技術センター (〒169-8612 東京都新宿区西早稲田 3-13-5)

E-mail: uehara.d@ckcnet.co.jp

⁴中央開発株式会社 技術センター (〒169-8612 東京都新宿区西早稲田 3-13-5)

E-mail: oji@ckcnet.co.jp

⁵鹿児島大学 学術研究院理工学域工学系 (〒890-0065 鹿児島市郡元 1-21-40)

E-mail: sako@oce.kagoshima-u.ac.jp

Key Words: sky view map, convolutional neural network, deep learning, high risk slopes

1. はじめに

飛騨川バス転落事故などを契機として昭和 43 年から開始された道路防災点検は、これまでに何度もその点検要領が改訂されながら継続的に実施されている¹⁾。道路防災点検は、机上調査と現地確認によって道路斜面災害リスク箇所(以下、災害リスク箇所)を抽出し、専門技術者による現地調査によって安定度調査を行うという流れである。過去の道路被災の多くは道路防災点検によって対策が必要と判断された箇所が発生しているものの、点検対象外からの災害や想定と異なる災害が発生した事例も報告されており、令和 4 年にも道路防災点検の手引きは改訂された¹⁾。この改訂では、国土交通省が推し進めている「三次元点群データを活用した道路斜面災害リスク箇所の抽出要領(案)²⁾」が取り入れられており、「道路防災点検における DX」を目指す内容に変更がなされた。具体的には、航空レーザー測量などに

よって取得された詳細地形の三次元点群データを用いて地形判読を行うことで、災害リスク箇所抽出におけるスクリーニングの精度向上を目指すというものである。

このような背景から、三次元点群データから微地形表現図^{3),4),5)}を作成し、災害リスク箇所の抽出に役立てる試みが多数行われている。本研究では、図-1 に示す Sky View Map⁵⁾(以下、SV マップ)を用いるが、このような微地形表現図を導入することで、過去の崩壊地形や滑落崖などを詳細に表現できるという利点がある。しかし、微地形表現図を用いた災害リスク箇所の抽出作業は、現状では技術者が微地形表現図を見ながら手作業で行っていることが多いため、災害リスク箇所の判読に時間がかかることや、技術者によって判読結果に個人差が生じる可能性があることなどが課題として挙げられる。そこで本研究では、災害リスク箇所を効率的かつ客観的に抽出するために、画像認識などの分野で実績のある深層

学習の方法である Convolutional Neural Network (以下, CNN) を用いて, 微地形表現図に基づく災害リスク箇所抽出モデルの構築を試みる. このようなアプローチは, 令和 4 年に改訂された道路防災点検の手引き¹⁾の中で記載されている「AI を用いた地形判読支援」とも合致する. 微地形表現図と深層学習を組み合わせた研究^{6),7)}はこれまでも行われているが, それらは比較的規模の大きい地すべりの自動判読を対象としており, 本研究では, より小さい範囲(5 m × 5 m)における災害リスク箇所を抽出できる CNN モデルの構築を試みる. また, 本研究で構築する災害リスク箇所抽出モデルは, 技術者が地形判読を行うための支援ツールという位置付けであり, CNN で技術者の災害リスク箇所抽出作業を代替しようとする自動判読のモデルとは異なる.

2. 適用データの作成

(1) 使用データ

SV マップは地形の傾斜, Sky View Factor (以下 SVF), Terrain View Factor (以下 TVF, 1-SVF) を重ね合わせて作成される微地形表現図⁹⁾である. SVF は地形の凹凸を表現した指標であり, 都市工学の分野では天空率として広く利用されている. 図-2 は SV マップを作成する際の各指標のカラーバーを示している. 各指標 (SVF, TVF, 傾斜) の値に応じたこれらの色情報 (RGB) を重ね合わせることで微地形を視覚的にわかりやすく表現できるマップを作成している. 図-1 に示した本研究で用いる SV マップは, 0.5 m 間隔の DEM データから作成されており, 南北に約 2.4 km, 東西に約 2 km の範囲の地形を表現している. この SV マップの色情報 (RGB) に基づいて各地点が災害リスク箇所に該当するかを判別する CNN モデルの構築を試みる.

図-1 に示す範囲の中から右上の南北に 1,200 m, 東西に 800 m の範囲を CNN モデル構築のための学習データとして用いて, 左下の南北に 360 m, 東西に 500 m の範囲を構築したモデルの汎化性能を評価するテストデータとして抽出した. 図-3 は学習データとテストデータの SV マップを示している. 図中における緑色のプロットは, 本研究で CNN モデルを構築する際の正解ラベルとなる災害リスク箇所を表している. これらのプロットは技術者が判別した滑落崖 (1 m 間隔) を 5 m 間隔のラスタデータに変換して表現している.

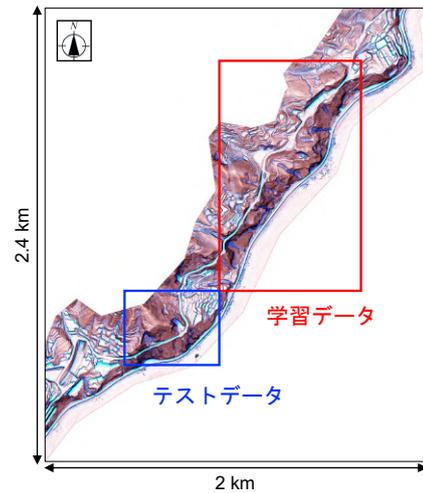
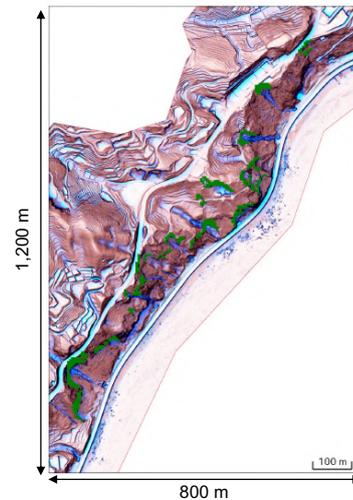


図-1 本研究で用いた SV マップ

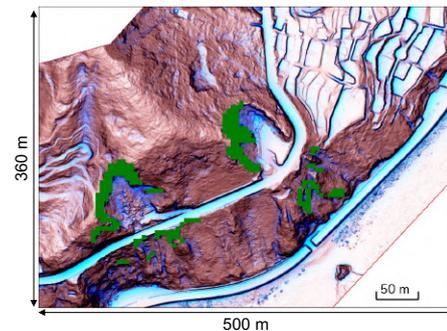
SVF	0.8(°)  1.0	覆い焼き・加算
TVF	0  0.1(°) RGB=0,128	覆い焼き・加算
傾斜	0  45(°) RGB=0,255,255	通常

(*) : 必要に応じて調整

図-2 SV マップを作成時の各指標のカラーバー



(a) 学習データ



(b) テストデータ

図-3 学習データとテストデータの SV マップ

(2) 入力データの作成

各地点が災害リスク箇所該当するかどうかを判別する CNN モデルを構築するために、その地点周辺の SV マップの色情報 (RGB) を入力データとして与える。図-4 は入力データの与え方を示している。各地点で対象とする $5\text{ m} \times 5\text{ m}$ の範囲に対して、その周りの $20\text{ m} \times 20\text{ m}$ の RGB と $100\text{ m} \times 100\text{ m}$ の RGB を入力データとして用いることとした。既往の研究⁸⁾において $20\text{ m} \times 20\text{ m}$ のデータを入力していたが、本研究では災害リスク箇所抽出の精度向上のためにより広域な地形情報 ($100\text{ m} \times 100\text{ m}$) も CNN モデルに学習させることとした。ただし、この範囲 ($20\text{ m} \times 20\text{ m}$, $100\text{ m} \times 100\text{ m}$) があらゆる災害リスク箇所抽出に対応できる範囲かは現時点では確認できておらず、適切な入力データの範囲に関する検討は今後の課題としている。本研究では、 20 m と 100 m という範囲の入力データを用いた場合に、災害リスク箇所抽出における支援ツールとして、構築された CNN モデルがどの程度活用できるかを確認するという位置付けである。このような入力データを 5 m ずつ移動させて、合計 30,800 個の学習データと合計 4,056 個のテストデータを作成した。また、SV マップが 0.5 m 間隔の DEM データから作成されているため、 $20\text{ m} \times 20\text{ m}$ の範囲には $40\text{ pixel} \times 40\text{ pixel}$ の RGB データがあり、 $100\text{ m} \times 100\text{ m}$ の範囲には $200\text{ pixel} \times 200\text{ pixel}$ のデータがある。これらを CNN に学習させるためにはデータの形式を統一させる必要があるため、 $100\text{ m} \times 100\text{ m}$ の範囲のデータを Average Pooling によって $40\text{ pixel} \times 40\text{ pixel}$ のデータに圧縮した。つまり、各データは $40\text{ pixel} \times 40\text{ pixel}$ のデータが 6 チャンネル (20 m の RGB と 100 m の RGB) 格納されており、それらのデータセットを学習データとしては 30,800 個、テストデータとしては 4,056 個用意した。図-5 はこのデータセットの作成方法を示している。

3. 解析手法

Convolutional Neural Network (CNN) は、中間層に畳み込み層とプーリング層を導入したニューラルネットワークモデルである。畳み込み層では、入力データにフィルタと呼ばれる畳み込み行列をかけることで特徴マップを出力する。フィルタは画像全体をスライドするため、画像の形状を保ちながら特徴を抽出できる。プーリング層では、畳み込み層から出力された特徴マップの重要な情報を維持しながら画像を圧縮する。例えば、Max Pooling では指定した範囲内の最大値を採用して、Average Pooling であれば平

均値を用いて画像を圧縮する。このような手順を繰り返すことで、CNN では入力データの形状や局所的な特徴を考慮しながら分類を行う。

図-6 は本研究で用いた CNN モデルの構造を示している。畳み込み層とプーリング層を 3 つ組み合わせており、出力層の活性化関数には Sigmoid 関数を用いて 0 から 1 の値を出力させた。正解ラベルが災害リスク箇所該当する場合は 1、該当しない場合は 0 に近づくようにモデルに学習させた。モデル構築時における最適化アルゴリズムは RMSprop、損失関数は binary_crossentropy を用いた。本研究のような 2 クラス分類問題には、binary_crossentropy が損失関数として用いられることが多く、RMSprop は勾配情報を用いてモデルパラメータを更新する最適化アルゴリズムである。最適化アルゴリズムはこの他にも多数存在するが、それらのアルゴリズムに関する議論は本研究の趣旨とは異なるため、本研究では代表的な最適化アルゴリズムとして RMSprop を用いることとした。

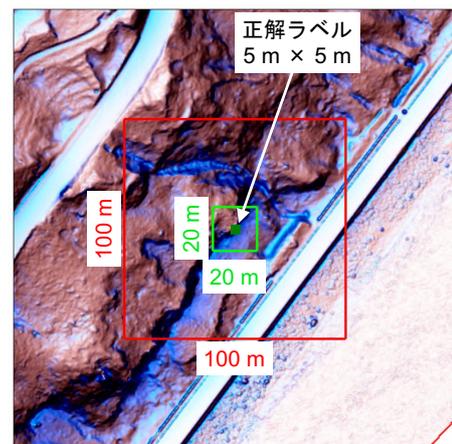


図-4 入力データの与え方

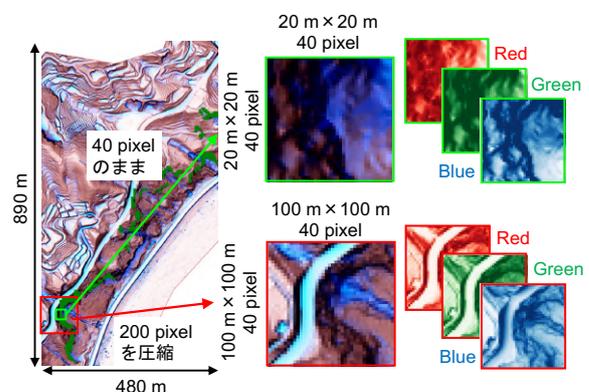


図-5 データセットの作成方法

4. 解析結果

(1) 入力データを正規化した場合の解析結果

RGBは0から255の値を取り、全てが0の場合は黒色となり、全て255の場合は白色となる。ここでは、まずRGBの情報を255で割って0から1の値を取るよう正規化した入力データを用いてCNNモデルを構築した。図-7は構築されたモデルに学習データを与えた場合と未学習のテストデータを与えた場合のCNNモデルの出力結果を示している。解析結果は0から1の値が出力されており、どの辺りが災害リスク箇所の候補地となるかを視覚的に把握することができる。図-3と比較して、構築されたCNNモデルは学習時に用いたデータだけでなく、未学習のテストデータにおける災害リスク箇所も概ね捉えられているといえる。なお、機械学習の分野では、出力された値が閾値(例えば、0.5)以上の場合は災害リスク箇所であると判別し、閾値以下の場合には災害リスク箇所ではないと判断して、混同行列を用いてその精度などを定量的に評価する方法がある。

表-1はテストデータに対する混同行列を示しているが、この結果からは構築されたCNNモデルの判別精度は高くないことがわかる。これは、未学習のテストデータにおける正解ラベルを5m間隔で正確に判別することは難しいことを意味している。ただし、図-7に示す出力結果は、災害リスク箇所のエリアの傾向は十分に捉えているため、技術者が地形判読を行うための支援ツールとしては有効な情報を提供できると考えられる。つまり、新たな地域で災害リスク箇所抽出を行う際に、まずCNNモデルにSVマップの色情報を入力することで災害リスク箇所の候補地となるエリアを視覚的に抽出できる。その後、その抽出されたエリア周辺を技術者が確認することで判読作業の効率化に繋がることが期待される。このような観点から、本研究では、視覚的に災害リスク箇所の候補地を把握でき、その確率も得られる図-7のような結果の出力方法を採用することとした。

SVマップは、災害リスク箇所に関する微地形を視覚的に把握しやすいように、平均的な傾斜量などに応じて色のパラメータを調整してマップを作成している。この色の調整は技術者の感覚に依る部分が大きく、極端な例を示せば、図-8に示すような薄いSVマップや濃いSVマップが作成される可能性もある。本研究で目指す災害リスク箇所抽出モデルは、ある地域のデータを用いてモデルを構築し、全く別の地域のSVマップを入力した際に災害リスク箇所の候補地を視覚的に示すことができるモデルであるため、

別の地域のSVマップとして色の濃淡が異なるマップが与えられた場合であっても災害リスク箇所を適切に推定できる必要がある。図-9は図-1に示す色のSVマップを用いて構築されたCNNモデルに対して、薄いSVマップのテストデータと濃いSVマップのテストデータを与えた場合の出力結果を示している。薄いSVマップを用いた場合は災害リスク箇所をほとんど抽出できておらず、反対に濃いSVマップを用いた場合は災害リスク箇所を過剰に抽出している。この結果は、SVマップの色の濃淡が変わると災害リスク箇所を適切に推定できないことを意味しており、本節で構築した災害リスク箇所抽出モデルは実用上意味がないといえる。

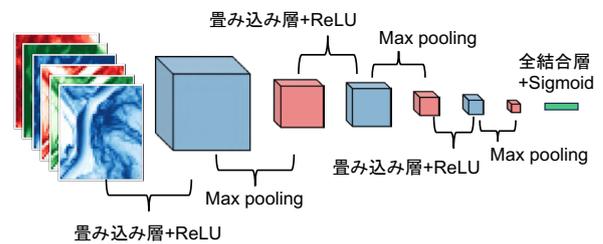
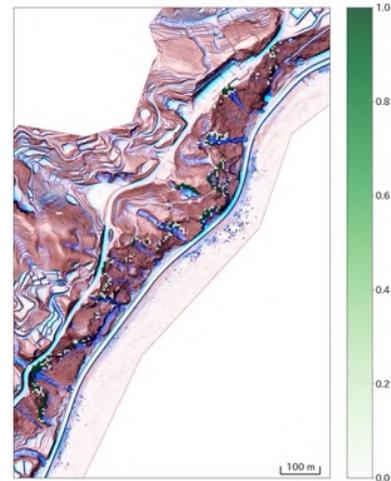
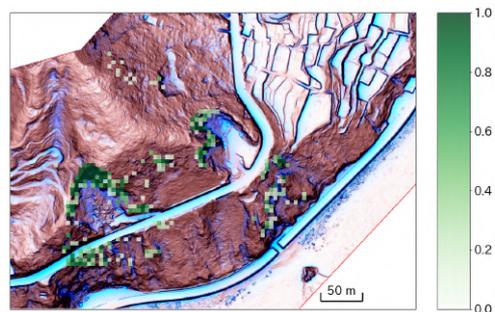


図-6 CNNモデルの構造



(a) 学習データ



(b) テストデータ

図-7 CNNモデルの出力結果

(2) 入力データを標準化した場合の解析結果

前節で構築したモデルが SV マップの色の濃淡が変わると災害リスク箇所を推定できなかった理由として、入力データの与え方に問題があったと考えられる。具体的には、RGB の情報を 255 で割って 0 から 1 の値に正規化した入力データを用いてモデルを構築したことで、**図-8** に示すような色の濃淡が異なる SV マップを、CNN モデルは学習していない別のマップだと認識している。そこで本節では、**図-1** に示す元々の SV マップと**図-8** に示す薄い SV マップと濃い SV マップの三つの RGB のデータを、それぞれ平均が 0、標準偏差が 1 になるように標準化したものを入力データとして扱うこととした。これにより、同一地点の入力データは、SV マップの色の濃淡が異なっても概ね近い値のデータになると想定される。**図-10** は標準化した入力データを用いて**図-1** に示す SV マップの学習データに基づいてモデルを構築し、色の濃淡が異なる三つの SV マップのテストデータを与えた場合の出力結果を示している。色の濃淡の違いによって出力結果は多少異なっているが、どの出力結果も**図-3** に示すテストデータの正解ラベルの位置を捉えられており、技術者が地形判読を行うための支援ツールとしては十分に有効であると考えられる。以上の結果から、SV マップのような地形によって色のパラメータが異なる可能性がある微地形表現図を用いて、学習していない地域の災害リスク箇所を抽出するモデルを構築するためには、入力データの標準化が必要であることがわかった。

表-1 テストデータに対する混同行列

		予測値	
		災害リスク箇所	非リスク箇所
正解値	災害リスク箇所	86	117
	非リスク箇所	98	3755

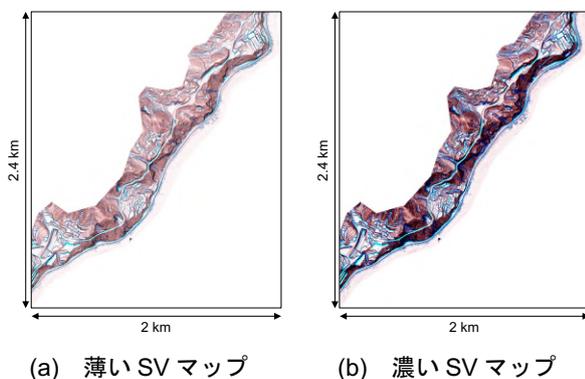
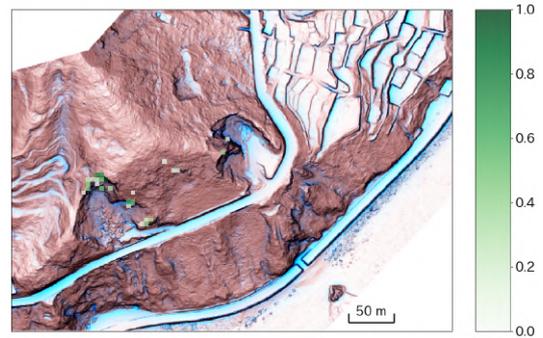
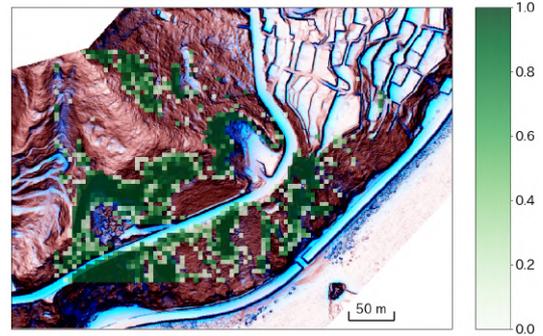


図-8 色の濃淡が異なる SV マップの例

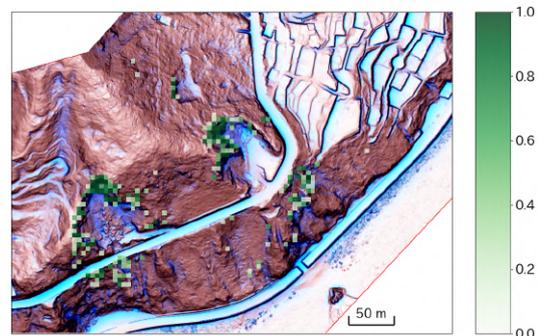


(a) 薄い SV マップ

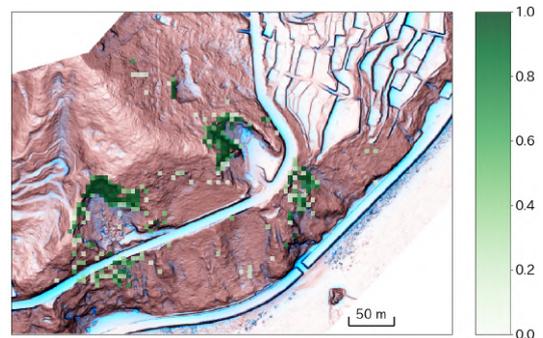


(b) 濃い SV マップ

図-9 構築されたモデルに対して色の濃淡の異なる SV マップのテストデータを与えた場合の出力結果

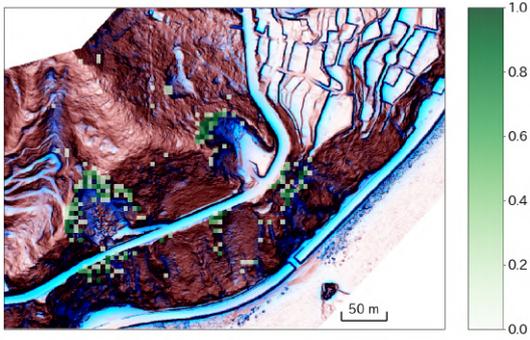


(a) 元々の SV マップ



(b) 薄い SV マップ

図-10 標準化した入力データを用いた場合のテストデータに対する出力結果



(c) 濃いSVマップ

図-10 標準化した入力データを用いた場合の
テストデータに対する出力結果

5. まとめ

本研究では、Convolutional Neural Network (CNN) を用いて微地形表現図(SV マップ)に基づく災害リスク箇所抽出モデルの構築を試みた。その結果、RGB の情報を正規化した入力データを用いて CNN モデルを構築すると、色の濃淡が異なる SV マップが与えられた場合に災害リスク箇所を適切に推定できないことがわかった。そこで、RGB の情報を平均が 0、標準偏差が 1 になるように標準化した入力データを用いて CNN モデルを構築することで、色の濃淡が異なる SV マップを用いてもテストデータの正解ラベルの位置を捉えた推定が可能であることが明らかになった。今後は、入力データの範囲が災害リスク箇所の抽出精度に与える影響について検討するとともに、構築したモデルを用いて学習には用いていない全く別の地域の災害リスク箇所抽出も試みる予定である。

謝辞：本研究で用いたデータの整理や分析は、藤門裕武氏(元鹿児島大学学生)と田中一字氏(鹿児島大学学生)にご協力いただきました。ここに記して謝意を表します。

SV マップは(株)STORY と中央開発(株)が共同開発したものである。

参考文献

- 1) 一般社団法人全国地質調査業協会連合会：道路防災点検の手引き(豪雨・豪雪等)[改訂版]—DX 時代に向けたチャレンジャー，2022.
- 2) 国土交通省：三次元点群データを活用した道路斜面災害リスク箇所の抽出要領(案)，2021.

- 3) 千葉達朗，鈴木雄介：赤色立体図—新しい地形表現手法—，応用測量論文集，15 巻，pp.81-89，2004.
- 4) 戸田堅一郎：航空レーザ測量データを用いた微地形図の作成，砂防学会誌，65 巻，2 号，pp.51-55，2012.
- 5) 上原大二郎，王寺秀介，鈴木雄介：「地質 DX」の取り組み，第 57 回地盤工学研究発表会，DS-6-01，2022.
- 6) 高山陶子，濱田耕平，花井健太，織田和夫，角田里美：ディープラーニングと赤色立体図を用いた微地形自動判読手法の検討，第 67 回砂防学会研究発表会，pp.697-698，2018.
- 7) 菊地輝行，崎田晃基，秦野輝儀，吉川慶，西山哲，大西有三：深層学習による崩壊・非崩壊の自動判別手法の開発，日本地すべり学会誌，56 巻，5 号，pp.255-263，2019.
- 8) 田中一字，藤門裕武，伊藤真一，西村修一，上原大二郎，王寺秀介：CNN による微地形表現図に基づいた道路斜面災害リスク箇所の抽出，令和 5 年度日本応用地質学会研究発表会，pp.91-92，2023.

(2024. 5. 31 受付)