

SAR 画像と地形的特徴を用いた CNN による崩壊地判読モデルの構築

CONSTRUCTION OF SEDIMENT DISASTER IDENTIFICATION MODEL
USING CNN BASED ON SAR IMAGES AND TOPOGRAPHICAL CHARACTERISTICS

藤門 裕武¹・伊藤 真一²・岩田 直樹³・鹿瀬 一希³・清水 則一⁴・酒匂 一成²

Hiromu FUJITO, Shinichi ITO, Naoki IWATA, Kazuki KANOSE,
Norikazu SHIMIZU and Kazunari SAKO

¹鹿児島大学大学院理工学研究科（〒890-0065 鹿児島県鹿児島市郡元 1-21-40）

²鹿児島大学学術研究院理工学域工学系（〒890-0065 鹿児島県鹿児島市郡元 1-21-40）

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

³中電技術コンサルタント株式会社（〒734-0001 広島県広島市南区出汐 2-3-30）

⁴山口大学大学院創成科学研究科（〒775-8611 山口県宇部市常盤台 2-16-1）

Key Words: convolutional neural network, sar images, topographical characteristics

1. はじめに

集中豪雨の増加により、毎年、全国各地で土砂災害が発生している。土砂災害発生直後は、初動対応（人命救助や避難経路の確保）が重要であり、そのためには、迅速かつ正確に崩壊地を把握する必要がある。通常、災害直後の崩壊地判読には、航空写真を用いることが多いが、この方法は航空機の使用にかかる費用が高額であることや悪天候時には航空機の使用が難しいことなどが課題として挙げられる。

近年、人工衛星に搭載された合成開口レーダ（Synthetic Aperture Rader, 以下 SAR）によって撮影された画像を用いた崩壊地判読が注目されている。SAR 画像は航空写真測量よりも安価であることに加えて、天候・昼夜を問わず観測することができる。また、日本上空を通過する人工衛星は現時点でも数多くあり、近年では、災害直後に人工衛星による緊急撮影が行われた事例も多数あることから、データのリアルタイム性という観点からも SAR 画像は活用できると考えられる。特に、同一地点における災害前後の SAR 画像の差分（強度差分 SAR 画像）を用いることで、崩壊地判読の精度向上も期待できる。強

度差分 SAR 画像を用いた崩壊地判読に関する研究^{1),2)}はこれまでにもいくつか行われているが、災害前後の観測間隔が長いと精度が低下することや、伐採地などの人工改変地を崩壊地と見誤りやすいなどの課題点が報告されている¹⁾。国土技術政策総合研究所によても SAR 画像を用いた土砂災害判読の手引き²⁾が提案されているが、災害の規模が小さいと検出率が低下することが課題点として挙げられる。近年は大規模な地すべりよりもがけ崩れや土石流の発生頻度が高い³⁾ことを考慮すると、比較的小規模な崩壊地も判読できる方法の確立が望ましい。鹿瀬ら⁴⁾は、表層崩壊に対する崩壊地の判読を目指して、強度差分 SAR 画像と地形的特徴（傾斜、ラプラシアン）を組み合わせた解析を行なったが、崩壊地判読の際の閾値の設定方法に課題があり、十分な精度での解析結果は得られなかった。

以上のように、強度差分 SAR 画像を用いた崩壊地判読は、大規模な地すべりに対しては成果をあげているものの、小規模な土砂災害に関しては、より高精度かつ客観的な崩壊地判読手法の確立が必要であるといえる。本研究では、そのための手段として、Convolutional Neural Network⁵⁾（以下、CNN）に注目

する。CNNはニューラルネットワークモデルの中でも画像認識に優れており、CNNによる深層学習を行うことで、高精度かつ客観的な崩壊地の判読が期待できる。本研究では、強度差分SAR画像と地形的特徴（傾斜、ラプラシアン）を入力して、その地域が崩壊しているかどうかを判別できるモデルの構築を試みる。さらに、その構築されたモデルの精度や課題についても議論する。

2. 適用データの作成

(1) 研究対象地域と使用データ

本研究では、平成30年7月豪雨によって多数の土砂災害が発生した広島県内の地域を研究対象とした。この地域では、多数の土石流が発生して道路に流木や泥流が流入した被害が報告されている。研究対象として2箇所の地域のデータ（航空写真測量による崩壊地判読結果、強度差分SAR画像、航空レーザ測量によるDEMデータ）が得られたため、図-1に示す地域（エリア①）をモデル構築のための学習データ、図-2に示す地域（エリア②）をモデルの汎用性を評価するためのテストデータとして用いた。図中の赤色の領域は実際の崩壊地点を意味しており、地理院タイル（平成30年7月豪雨 正射画像）の崩壊地をトレースして作成した。強度差分SAR画像に関しては、衛星の進行方向が異なる ascending（北行軌道）と descending（南行軌道）の2種類のデータを用いた。ascendingは平成30年3月（災害前）と平成30年7月末（災害後）の差分を、descendingは平成30年6月（災害前）と平成30年8月（災害後）の差分を用いて作成した。なお、強度差分SAR画像は崩壊前の後方散乱係数から崩壊後のそれを引いた差分で算出している。DEMデータに関しては、データ間隔は1m（メッシュ）であり、エリア①は南北に3,000m、東西に4,000mの合計1,200万メッシュ、エリア②は南北に3,000m、東西に6,000mの合計1,800万メッシュのデータを用いて分析を行った。なお、崩壊地判読結果はDEMデータと対応した位置における崩壊・非崩壊に関する情報が得られている。

(2) ラベルの作成

CNNモデルを構築するための正解値となるラベルを作成する。用いたDEMデータのメッシュ数が膨大であるため、DEMデータの地点ごとにラベルを作成するとCNNモデル構築時に非効率的な学習となりモデルの精度が低下することが既往の研究⁶⁾によつて分かっている。そこで本研究では、図-3に示

すように、20m×20m（合計400個の崩壊データ）の範囲ごとにラベルを作成し、その範囲内で図-1や図-2に示す崩壊地点が多ければそのラベルを1として、崩壊地点が少なければラベルを0とした。ラベルにおける1 or 0の閾値に関しては、図-1、図-2と違いが出ないように、400個の崩壊データの内に何個以上崩壊地点が含まれる場合を1とするかを検討したところ、40個（10%）が妥当であったため、40個以上の崩壊地点が含まれる場合を1として赤色で塗りつぶし、それ以下の場合を0とした。図-4は本研究で用いたエリア①のラベルを示しており、図-5はエリア②のラベルを示している。図-1、図-2と比較して、概ね類似した崩壊箇所が示されているため、本研究ではこれらをCNNモデル構築時のラベルとして用いることとした。なお、図-3に示すように、入力データの関係で、ラベルは対象範囲よりも内側で作成しているため、ラベル数としてはエリア①が $148 \times 198 = 29,304$ 個、エリア②が $148 \times 298 = 44,104$ 個となる。

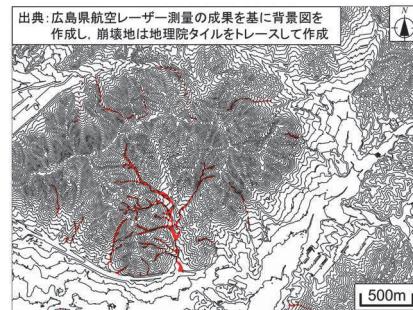


図-1 エリア①における実際の崩壊地

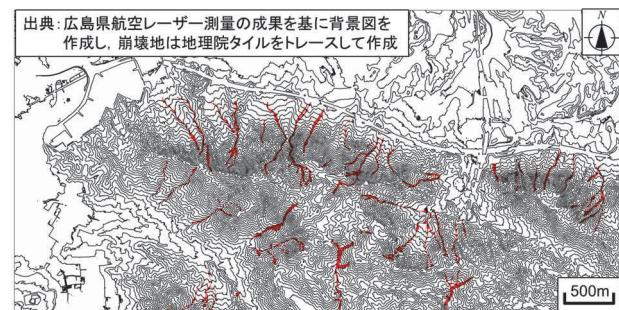


図-2 エリア②における実際の崩壊地

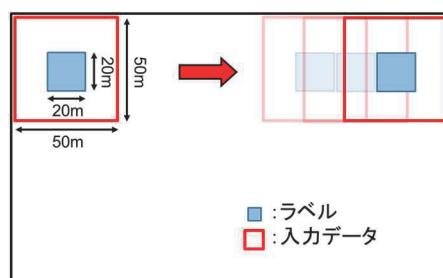


図-3 ラベル作成の流れ

(3) 入力データの作成

CNN モデルに入力するデータを作成する。地形的特徴に関してはいくつかの指標が考えられるが、既往研究で実績のある傾斜 (DEM データの 1 階微分) とラプラシアン (DEM データの 2 階微分) を採用した。図-6 のように地形的特徴を算出する該当地点の標高値 (Z) とその周辺の標高値 (Z_N, Z_S, Z_W, Z_E) を定義すると、傾斜 $angle^7)$ は式(1)のように算出される。

$$angle = \frac{360}{2\pi} \cdot \arctan \left\{ \sqrt{\left(\frac{Z_E - Z_W}{2\Delta x} \right)^2 + \left(\frac{Z_N - Z_S}{2\Delta y} \right)^2} \right\} \quad (1)$$

ラプラシアン $lap^7)$ は式(2)のように算出した。ラプラスは地形の凹凸を表しており、プラスが凹地形、マイナスが凸地形を意味している。

$$lap = \left(\frac{Z_E - 2Z + Z_W}{\Delta x^2} \right) + \left(\frac{Z_N - 2Z + Z_S}{\Delta y^2} \right) \quad (2)$$

図-7 はエリア①における傾斜の分布図を示しており、図-8 はラプラシアンの分布図を示している。

次に、強度差分 SAR 画像のデータを整理する。DEM データが平面直角座標系でデータが格納されておりデータ間隔が 1m であるのに対して、強度差分 SAR 画像は緯度・経度でデータが格納されており、これを平面直角座標系に変換するとデータ間隔は約 2.5m となるため、地形的特徴と強度差分 SAR 画像はデータの座標が一致しない。CNN によるモデル化を考えるとデータの位置座標を一致させておく必要がある。このような場合の内挿方法はいくつかあるが、本研究では膨大なデータ処理に際しての演算負荷を低減するため、比較的簡易な次式を用いて、DEM データがある位置に強度差分 SAR 画像の情報を内挿した。

$$sar = \frac{\sum w(r) \cdot ref}{\sum w(r)} \quad (3)$$

ここで、 ref は位置合わせ前の強度差分 SAR 画像の反射強度、 $w(r)$ は距離による重みを意味しており、重み $w(r)$ は次式のように算出される⁸⁾。

$$w(r) = \begin{cases} \frac{r_e}{r} - 1, & 0 \leq r \leq r_e \\ 0, & r_e \leq r \end{cases} \quad (4)$$

ここで、 r_e は影響半径、 r は DEM データと SAR データの距離を表している。これらの式から、影響半径 r_e よりも外側の強度差分 SAR 画像の重みは 0 となり、影響半径より内側の強度差分 SAR 画像は対象

の DEM データに近いものほど強く重み付けをされることがわかる。影響半径 r_e に関しては、渓流の幅などを考慮して $r_e=10m$ とした。以上のデータ整理を

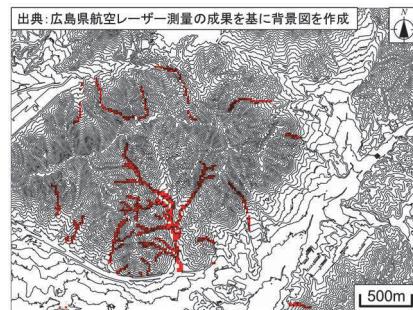


図-4 エリア①におけるラベル

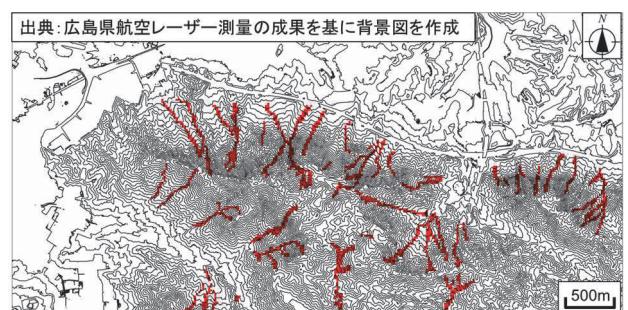


図-5 エリア②におけるラベル

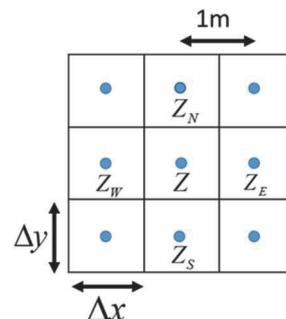


図-6 地形的特徴の算出に関する各記号の定義

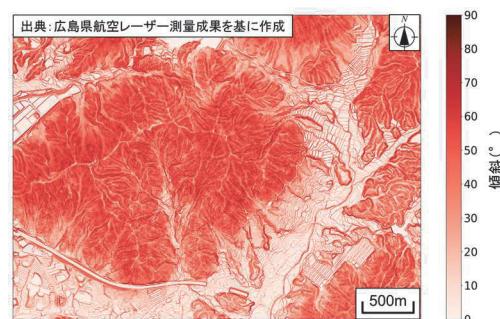


図-7 エリア①における傾斜の分布図

行って、データ間隔が 1m である強度差分 SAR 画像 (*sar*) を作成した。図-9 は座標合わせ後のエリア①における ascending の強度差分 SAR 画像を示しており、図-10 は descending の強度差分 SAR 画像を示している。

以上のようにして算出された図-7 から図-10 のデータを CNN モデルに対する入力データとする。入力データに関しては、ラベルの範囲 (20m×20m) よりも広域の情報を CNN モデルに学習させるために、図-3 に示すような 50m×50m の範囲の傾斜、ラプラシアン、強度差分 SAR 画像 (ascending と descending) をそれぞれ合計 29,304 枚与えることとした。

3. 解析手法

(1) Convolutional Neural Network の概要

CNN はニューラルネットワークモデルにおける中間層に畳み込み層とプーリング層を導入することで、入力データから特徴を抽出して、その情報を維持したまま画像を圧縮することができる。この特徴により、CNN は画像認識などの分野で数多く適用されている。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 プーリングは指定した範囲内の最大値のみを採用することで画像のサイズを圧縮している。このような畳み込みとプーリングを繰り返すことで、CNN は入力データの形状や局所的な特徴を考慮して画像サイズを小さくして分類を行うことができる。

(2) 解析条件

Python 用のニューラルネットワークフレームワークである Keras⁹⁾を用いて CNN による崩壊地判読モデルを構築した。図-11 は本研究で構築した 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の 2 層を 4 つ組み合わせており、畳み込み層の活性化関数には次式に示す ReLU を用いた。

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (5)$$

出力層の前に全結合層を導入しており、出力層の活性化関数は次式に示す Sigmoid 関数を用いた。

$$f(x) = \frac{1}{1 + e^{-ax}} \quad (a > 0) \quad (6)$$

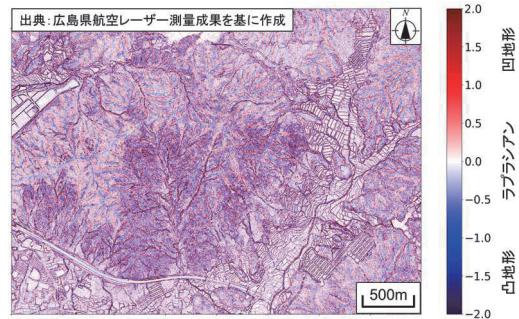


図-8 エリア①におけるラプラシアンの分布図

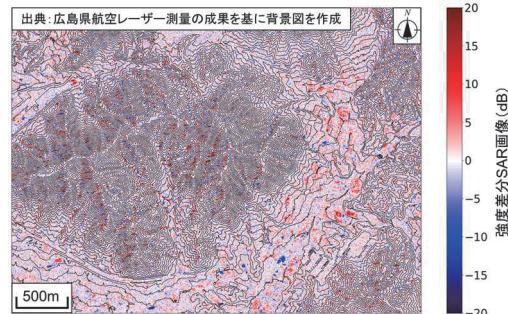


図-9 エリア①における強度差分 SAR 画像
(ascending)

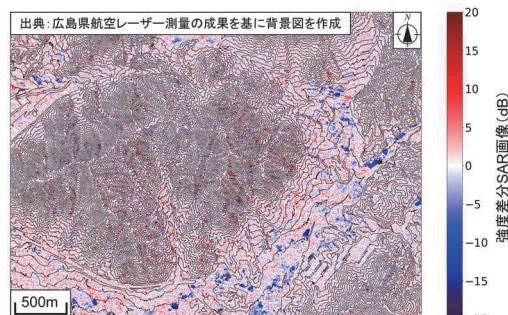


図-10 エリア①における強度差分 SAR 画像
(descending)

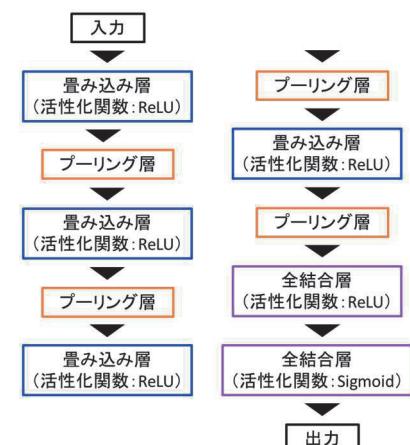


図-11 CNN モデルの構成図

Sigmoid 関数は 0 から 1 の値を取るため、出力層からは Sigmoid 関数の予測値に基づくスコア (0 から 1 の値) が出力される。本研究では、機械学習の分野で一般的に使われる閾値として、出力されたスコアが 0.5 以上の場合は崩壊、それ以下の場合は非崩壊と判別した。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 を用いて、エポック数は 500 とした。

4. 解析結果

エリア①の学習データを用いて CNN による崩壊地判読モデルを構築した。図-12 は構築されたモデルに対して学習データの地形的特徴（傾斜、ラプラス）と強度差分 SAR 画像（ascending と descending）を入力した場合の再現解析結果を示している。構築されたモデルによる解析結果は、図-4 に示すラベルを良好に再現できていることがわかる。ラベルに対する再現性を定量的に評価するために、混同行列¹⁰⁾を用いて精度、適合率、再現率を算出した。混同行列とは、分類結果を評価する方法の一つであり、真陽性（True Positive）、真陰性（True Negative）、偽陽性（False Positive）、偽陰性（False Negative）を表-1 のように表現したものである。精度、適合度、再現率に関してはそれぞれ以下のように表される。

$$\text{精度} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

$$\text{適合率} = \frac{TP}{TP + FP} \quad (8)$$

$$\text{再現率} = \frac{TP}{TP + FN} \quad (9)$$

表-2 は学習データに対する再現解析結果の混同行列を示している。これらの結果から、精度：99.2%、適合率：86.3%、再現率：87.2%となり、構築されたモデルは、学習データに対しては、定量的にも高い精度でラベルを再現できているといえる。

次に、構築されたモデルに対して未学習のテストデータを与えてモデルの汎化性能を評価した。図-13 は構築されたモデルにテストデータを入力した際の予測解析結果を示しており、表-3 はその混同行列を示している。また、図-14 は入力したエリア②の強度差分 SAR 画像（ascending）を示している。混同行列から算出される精度、適合度、再現率はそれぞれ精度：96.0%、適合率：50.2%、再現率：57.5% である。テストデータに関しても、図-5 のラベルと比較して

全体的に渓流沿いに崩壊地が多い傾向は表現できており、精度も 96.0% と高い数値を得ることができて いる。しかし、適合率、再現率は 50% 台と低い値になつておらず、未学習のテストデータに対しても汎化性能の高いモデルを構築できたとはいえない。ただし、SAR 画像を用いた崩壊地判読の主要な目的は、災害直後の初動対応である。その際に重要なのは

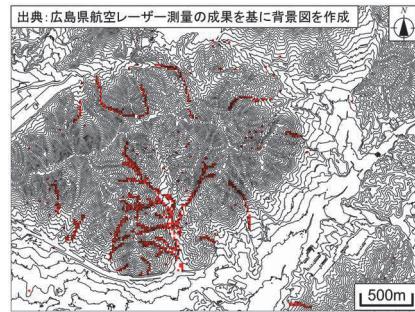


図-12 CNN モデルに学習データを適用した場合の再現結果

表-1 混同行列

		予測	
		0	1
実績	0	真陰性 (TN)	偽陰性 (FP)
	1	偽陰性 (FN)	真陽性 (TP)

表-2 学習データに対する再現解析結果の混同行列

		予測	
		0	1
実績	0	28344	117
	1	108	735

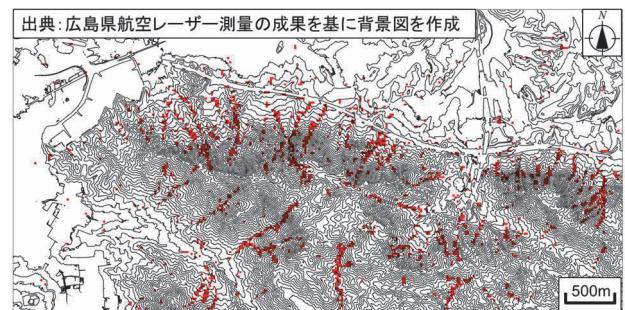


図-13 CNN モデルにテストデータを適用した場合の予測結果

表-3 テストデータに対する予測解析結果の混同行列

		予測	
		0	1
実績	0	41348	1000
	1	747	1009

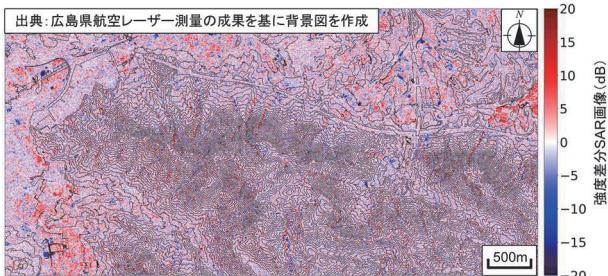


図-14 エリア②における強度差分 SAR 画像
(ascending)

は、災害の発生地点や規模を概略的に把握することで、その観点で考えると、本研究の成果でも十分に活用できる可能性はあると考えられる。しかし、本研究で対象とした地域は、ほとんどの渓流で土石流が発生しているため、強度差分 SAR 画像の情報よりも地形的特徴の方が崩壊地判読結果に大きく影響している可能性も考えられる。これはモデルの学習方法や入力データの問題ではなく、対象とした地域の問題であるため、今後は、土石流が発生した渓流と発生していない渓流が混在しているような地域を対象として同様の検証を行う必要がある。また、本研究では、地形的特徴として傾斜とラプラスアンを学習させたが、これらの他にも、集水面積やその他の地形的特徴、植生なども土石流の要因として考えられるため、今後は様々な要因を考慮したモデル構築を検討する必要がある。

5. まとめ

本研究では、強度差分 SAR 画像と地形的特徴を用いた CNN による崩壊地判読モデルを構築し、そのモデルの適用性と課題について明らかにすることを目的として解析を行った。得られた知見を以下に示す。

- (1) CNN によって構築された崩壊地判読モデルを用いることで、学習データ（モデル構築時に学習させたデータ）に関しては、崩壊地を概ね再現することができる事がわかった。
- (2) CNN によって構築された崩壊地判読モデルは、テストデータ（モデル構築時に学習させていないデータ）に関しては、崩壊地の全体的な傾向自体は表現できていたものの、適合率、再現率は低いという結果となった。ただし、初動対応という観点においては本研究の成果も活用できる可能性はあると考えられる。
- (3) 今後は、土砂災害が発生している渓流と発生していない渓流が混在する地域でも同様の検討を

行うことに加えて、入力データに集水面積などを導入することで、SAR 画像を用いた崩壊地判読モデルの高度化を行う必要がある。

謝辞:本研究を実施するにあたって、広島県から DEM データを、宇宙航空研究開発機構（JAXA）から ALSO-2/PALSER-2 の観測データ（山口大学と JAXA との協定に基づく）を提供いただきました。ここに感謝の意を表します。

参考文献

- 1) 山下久美子、佐藤匠、引地慶多、川島祐人、鈴木大和、松田昌之、中谷洋明 : SAR 強度画像を用いた土砂移動箇所検出特性と課題 -令和 2 年 7 月豪雨の事例-, 2021 年度砂防学会研究発表会概要集, pp.135-136, 2021.
- 2) 鈴木大和、松田昌之、瀧口茂隆、野村康裕、山下久美子、中谷洋明 : 合成開口レーダ（SAR）画像による土砂災害判読の手引き, 国土技術政策総合研究所資料, Vol.1110, 2020.
- 3) 国土交通省 水管理・国土保全局 砂防部 平成 30 年 7 月豪雨による土砂災害概要
https://www.mlit.go.jp/river/sabo/jirei/h30dosha/H3_0_07gouu_gaiyou1807311800.pdf, 2021.12.1
- 4) 鹿瀬一希、岩田直樹、荒木義則、清水則一 : 平成 30 年 7 月豪雨災害を事例とした強度差分 SAR 画像による崩壊地判読の精度の検証, 砂防学会研究発表会概要集, Vol.70, pp.541-542, 2021.
- 5) Y.Lecun, L.Bottou, Y.Bengio, P.Haffner : Gradient-based learning applied to document recognition, Proceedings of the IEEE, Vol.86, pp.2278-2324, 1998.
- 6) 藤門裕武、伊藤真一、酒匂一成、岩田直樹、鹿瀬一希、笛田泰成 : SAR 画像を用いた崩壊地判読に対する CNN の適用性の検証, 土木学会西部支部研究発表会, pp.309-310, 2022.
- 7) 佐藤丈晴、中島翔吾 : 大規模崩壊の兆候となる微地形の抽出方法－天川村における評価事例－, 日本地すべり学会誌, Vol.52, pp.141-145, 2015.
- 8) 岩本哲也、小野祐輔 : 弹性波伝搬問題に対する粒子法の適用性, 応用力学論文集, Vol.12, pp.611-622, 2009.
- 9) Francois Chollet : Python と Keras によるディープ ラーニング, マイナビ出版, 2019.
- 10) Andreas C. Muller, Sarah Guido: Python ではじめる 機械学習, オライリージャパン, 2017.

(2022.5.30 受付)