

航空レーザ計測のオリジナルデータを用いた DNN と CNN による土砂移動検出

LANDSLIDE DETECTION METHOD USING DNN AND CNN
WITH ORIGINAL DATA FROM AIRBORNE LIDAR

平川 泰之¹・光永 海斗¹・佐藤 丈晴²

Yasuyuki HIRAKAWA, Kaito MITSUNAGA and Takeharu SATO

¹株式会社オリエンタルコンサルタンツ九州支社 (〒812-0011 福岡市博多区博多駅前 3-2-8)

E-mail: hirakawa-y@oriconsul.com

²岡山理科大学生物地球学部 (〒700-0005 岡山市北区理大町 1-1)

E-mail: sato@ous.ac.jp

Key Words: Airborne LiDAR, original data, landslide detection, deep neural network, convolutional neural network

1. はじめに

大規模土砂災害発生後には土砂移動の分布や規模を迅速に把握することが求められる。それに供する観測データのうち現時点で最も早く得られるものは衛星 SAR 画像であるが、強度差分 SAR 画像から熟練技術者が目視判読する必要があるため汎用的でなく、また検出率は条件によって異なるが 2 割～7 割程度であり¹⁾、実用可能なレベルにあるとはいえない。次に得られるデータとしては、光学衛星や航空機による空中写真が挙げられる。2024 年 1 月 1 日の能登半島地震では空中写真判読により、国土地理院が最短わずか 3 日後に崩壊・堆積分布図を公開した²⁾。しかしこのような目視判読作業には人的リソースを短期集中投入していると想像され、効率化が求められる。また SAR 画像解析と写真判読のいずれでも得られるのは土砂移動域のみであり、生産・堆積土砂量を計測することはできない。

近年では土砂量把握のためには航空レーザ計測 (以下 LP) を行い、災害前の LP データ等との差分解析によって算出する手法がとられる事が多い。しかしこの場合、LP のオリジナルデータからグリッドデータを製作するフィルタリング工程と、差分図や

オルソフォト等を用いた土砂移動域の目視判読作業に時間を要することが問題である。

そこで筆者らは、災害後のフィルタリングを待たずにオリジナルデータを使用し、また目視判読作業を AI による推論に置き換えることによって、短時間で土砂移動を検出する技術を開発した (図-1)。AI の手法として、隣接メッシュとの関係性を考慮せずメッシュ単位で解析する DNN (Deep Neural Network) と、画像として解析する CNN (Convolutional Neural Network) の 2 ステップを行う点が特長である。

2. 研究対象領域と使用データ

研究対象領域は、2016 年熊本地震で土砂災害が多発した阿蘇地域と、2018 年西日本豪雨で土砂災害が多発した広島地域のうち、樹林部とした (図-2)。阿蘇地域の土砂移動は尾根部を含めて幅広い形態の斜



図-1 LP 計測～土砂移動把握における本研究の位置づけ

面で発生しており、土砂移動形態の多くは比較的深い崩壊や地すべりであり、あまり長い距離を流下せずに発生源の直下で堆積している。一方で広島地域の土砂移動の多くは谷地形で発生し長距離を流下した土石流である。このような土砂移動形態の特徴は誘因（地震か豪雨か）の違いを反映していると考えられる。本研究では誘因によらず幅広い土砂移動に対応するため、この両地域を選定した。

樹林部のみを対象とした理由は、樹林部以外では土砂移動による差分値が数センチ～数十センチ程度と計測誤差に近いオーダーになるため、土砂移動検出が困難であり、学習データに混在させると学習精度の低下を招くこと、および、一般的には大規模土砂災害の発生源の多くが樹林部に存在するため、樹林部のみを対象とした推論モデルであっても実用的価値があると考えたことによる。

本研究では短時間での土砂移動検出を目的とするため、災害後 LP については製作に時間を要するグリッドデータを使用せず、オリジナルデータのみを使用することとした。これに加えて災害前 LP のオリジナルデータ及びグリッドデータの、計 3 種類のデータのみを使用した。LP 計測年は阿蘇地域では災害前 2013 年と災害後 2016 年、広島地域では同じく 2017 年と 2018 年である。正解としての土砂移動域は、阿蘇地域については災害前後の LP 差分結果とオルソフォトから筆者らが判読したものを使用し、広島地域については既往調査成果³⁾を使用した。

3. 研究方法

(1) 概要

本研究で開発した推論モデルは次の 2 ステップで

構成される。第 1 ステップは 5m メッシュ単位で、隣接メッシュとの関係を考慮せずに推論する 2 値分類であり、DNN を用いた。DNN は脳の神経回路をモデル化した Neural Network の一種で、入力層、2 層以上の中間層、および出力層の構造を有するものである。第 2 ステップは、第 1 ステップの結果を用いて推論するセマンティック・セグメンテーションであり、CNN を用いた。セマンティック・セグメンテーションとは画像認識技術の 1 つで、画像の 1 ピクセル毎にラベル（本研究では土砂移動の有無）を割り付けるものである。CNN も Neural Network の一種であり、畳み込み層によって隣接ピクセルとの関係性から画像の特徴を抽出することができる。解析ソフトとしてはいずれも、コーディング無しで AI 開発可能な Sony 社製 Neural Network Console を用いた。

(2) 第 1 ステップの解析方法

初めに対象範囲内を 1m メッシュに区切り、各メッシュ内の災害前・災害後それぞれのオリジナルデータの最大値を採用して簡易な DSM (Digital Surface Model) を作成した。また災害前のグリッドデータより 1m メッシュの DEM (Digital Elevation Model) を作成した。これらより GIS の機能を用いて下記の 2 種類の差分値 a_1, a_2 を算出した上で、計算負荷の低減のため 5m メッシュにリサイズした。

$$a_1 = z_{DSM2} - z_{DEM1} \quad (1)$$

$$a_2 = z_{DSM2} - z_{DSM1} \quad (2)$$

ここに、 z_{DEM1} は災害前 DEM の標高、 z_{DSM1} は災害前 DSM の標高、 z_{DSM2} は災害後 DSM の標高である。樹林地で土砂移動が発生した場合の a_1, a_2 のイメージを図-3 に示す。土砂生産域（崩壊・侵食部）では樹林が消失した上で地盤高も低下するため、 a_1 がや

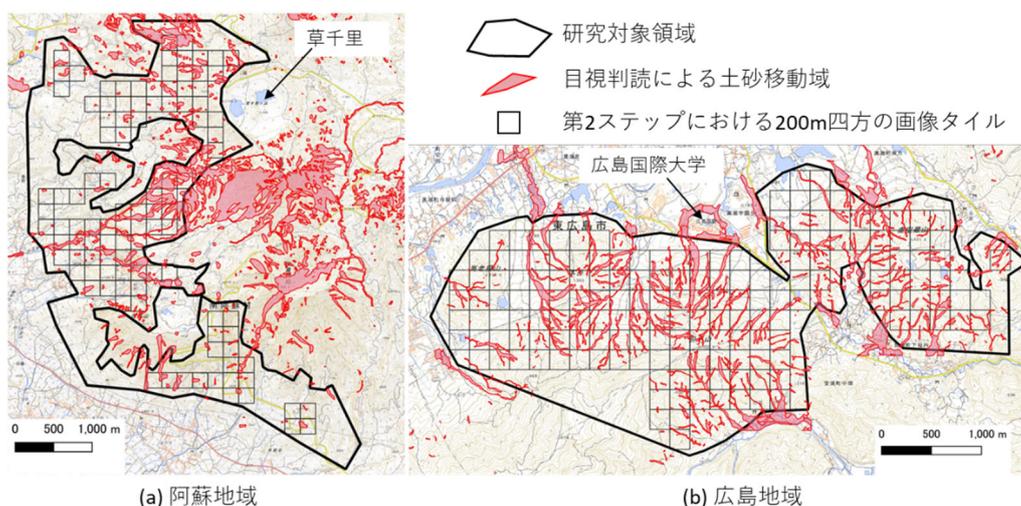


図-2 研究対象領域位置図

やマイナス、 a_2 は樹高に相当する大きなマイナスを示し、比較的容易に検出できると期待される。一方で堆積域では樹林消失を伴わなければ検出は不可能で、樹林消失を伴う場合であっても a_1 がプラスであるため樹林との差異が不明瞭で、検出しにくいことが予想される。

上記の a_1, a_2 を説明変数とし、土砂移動の有無を表す2値ラベルを目的変数とするDNNの推論モデルを構築した。対象領域内から学習データと検証データの割合が7:3程度となり、かつそれぞれにおいて土砂移動あり・なしのメッシュ数が同数になるように、5mメッシュを抽出した。学習・検証の各データ数を表-1左列に示すが、これは図-2に示した研究対象領域全体の5mメッシュ数750,288個の7.6%にあたる。このデータを用いてDNNによる推論モデルを構築した上で、対象領域全体に対する推論を行った。

DNNのレイヤ構造やパラメータの設定に当たっては、比較的単純なモデルを設定した後に、Neural Network Consoleの構造自動探索機能を用いて、精度の高いものを選定した。

(3) 第2ステップの解析方法

第1ステップの解析の結果では、土砂生産域は良く検出できていたが、堆積部の検出漏れが多い点と、小面積のノイズ状の誤検出が多い点が問題であった(図-4)。第1ステップの推論結果を画像化したもの

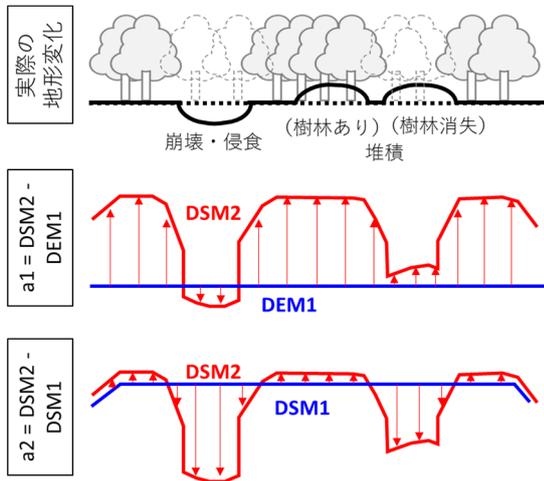


図-3 土砂移動に伴う地形変化のイメージ

表-1 学習・検証用のデータ数

	第1ステップ (メッシュ数)	第2ステップ (画像数)
学習データ	39,894	1,604
検証データ	17,098	688
合計	56,992	2,292

に比較的単純なCNNモデルを適用するという試行を行った結果、ノイズ状の誤検出はかなり除去できたが、検出漏れが増加し、また堆積部の検出漏れは改善できなかった。これは第1ステップの解析結果の各メッシュが0か1の情報しか持たないからである。そこで第1ステップの推論結果に加えて、 a_1 と a_2 を加工した画像を再度入力するとともに、地形を表すMPI (Morphometric Protection Index)を追加し、計4種類の入力画像を使用するCNNモデルを構築した。 a_1, a_2 およびMPIの画像について以下に説明する。

a_1 は0~20mの範囲を255~0に変換したグレースケール画像とした(図-5)。これは、 a_1 が大きい箇所は土砂移動が発生していないため樹高を示しており、逆に小さい箇所は土砂移動が発生している可能性が高いとの考えによる。変換後の値が大きい(画像としては白い)方が、土砂移動発生の可能性が高くなるようにした。20mという値は、多くの場合樹高はその程度に収まるという値として設定した。

a_2 は-20~0mの範囲を255~0に変換したグレースケール画像である(図-6)。この意図は、樹林が消失した箇所は土砂移動が発生した可能性が高いとの考えにより、その他の考え方は上記と同様である。

MPIは災害前DEMからSAGA GISによって算出した。MPIはSAGA GISの説明⁴⁾によれば「ある地点が周辺地形によってどの程度守られるか」を表すものであり、地上開度⁵⁾と同様の意味を持つとされ、0~1の範囲で尾根ほど小さく、谷ほど大きな値を取る(図-7)。本研究では第1ステップで土砂生産域を良

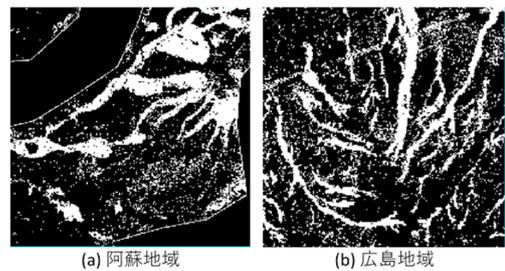


図-4 第1ステップの推論結果

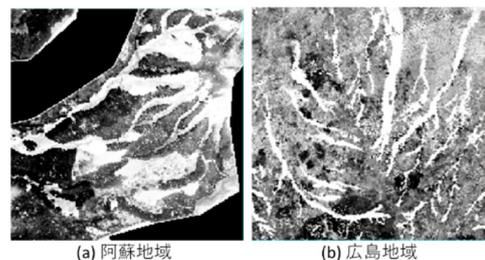


図-5 a_1 を変換したグレースケール画像

く検出できていたので、第2ステップでは「土砂生産域に近い谷部では土砂堆積の可能性が高い」ということを学習させる意図で、谷部が大きな値を示すMPIを入力画像に加えた。

正解画像は、目視判読結果を用いて土砂移動ありの画素に255、土砂移動なしの画素に0を割り当てた。以上で作成した4種類の入力画像と正解画像について、土砂移動が見られる範囲（研究対象領域の約6割に相当）を40 pixel 四方（200m 四方）のタイル状に分割した(図-2)。さらに縦・横とも20 pixel ずらしたタイル状画像と、それらを90度ずつ回転した画像を作成した上で、7:3 で学習データと検証データに分割した。学習・検証データの画像数を表-1 右列に示す。このデータを用いてDNNによる推論モデルを構築した上で、対象領域全体に対する推論を行った。ここで、モデルの汎用性を評価するためには学習・検証データ以外の領域（テスト領域）で精度評価すべきであるが、本研究では十分なデータ数を確保する事を優先して上記のように6割を学習・検証データに費やした。テスト領域のみでの精度評価は今後の課題としたい。

CNN のレイヤ構造やパラメータの設定に当たっては、比較的単純なモデルを設定した後に、Neural Network Console の構造自動探索機能を用いて、精度の高いものを選定した。なお、第1ステップを経ずに a_1, a_2 と MPI を入力として直接 CNN で解析する手法も試みたが、良い結果は得られなかった。

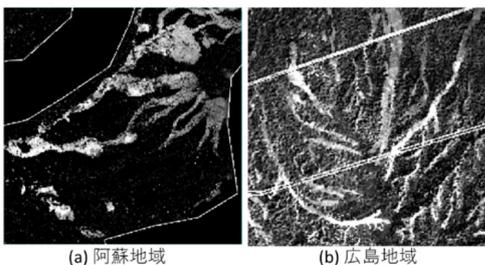


図-6 a2 を変換したグレースケール画像

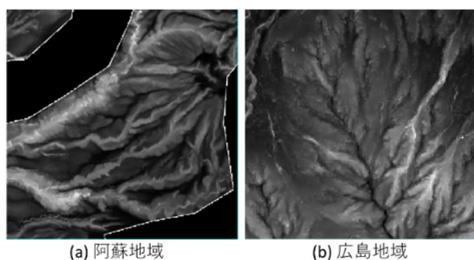


図-7 MPI を変換したグレースケール画像

(4) 土砂量の算出方法

「土砂移動あり」と推論されたメッシュの a_1 の値のうち、マイナス部分とプラス部分をそれぞれ集計し、1メッシュあたり面積である $25m^2$ を乗じて、それぞれ生産土砂量と堆積土砂量の推論値とした。

(5) 評価方法

土砂移動域の推論に対する精度評価指標値としては、各メッシュの推論結果と正解値を比較して表-2 の各項に該当するメッシュ数を集計し、下式に示す *Accuracy* (正解率), *Precision* (適合率), *Recall* (再現率), および *IoU* を算出した。

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (3)$$

$$Precision = TP/(TP + FP) \quad (4)$$

$$Recall = TP/(TP + FN) \quad (5)$$

$$IoU = TP/(TP + FP + FN) \quad (6)$$

IoU は正解と推論結果の画像の重なり具合を示す指標である。一般に誤検出と検出漏れはトレードオフの関係にあるが、*IoU* は誤検出と検出漏れの両方をバランス良く低減できているかを評価することができる。気象や土砂災害の未来予測に用いられるスレットスコアと同義である。

また土砂量については、災害後 DEM と災害前 DEM の差分解析結果を目視判読による土砂移動域内で集計し、生産・堆積土砂量の正解値とした。正解値と推論値の差を正解値で除したものを、土砂量の誤差率とした。

4. 結果と考察

(1) 各ステップの推論結果

正解画像と第2ステップの推論結果の比較を、図-8 および図-9 に示す。第1ステップ(図-4)で多く見られたノイズ状の微少箇所や直線状の送電線の誤検出は、第2ステップでほとんど解消できた。また図-10 の拡大図に示すように、堆積部の検出漏れは第2ステップでも完全には解消できなかったものの、若干の改善が見られた。

各ステップにおける解析結果の混同行列を表-3 に、精度評価指標値を表-4 に示す。表-3 を見ると第

表-2 精度評価における混同行列

	推論結果	土砂移動あり	土砂移動なし
正解			
土砂移動あり		TP (的中)	FN (検出漏れ)
土砂移動なし		FP (誤検出)	TN (的中)

1 ステップから第 2 ステップにかけて、誤検出が 63,689 から 13,102 へと大きく減少しており、この結果再現率以外の全ての精度指標値が大きく改善した。一方で検出漏れは 19,450 から 18,871 へと若干

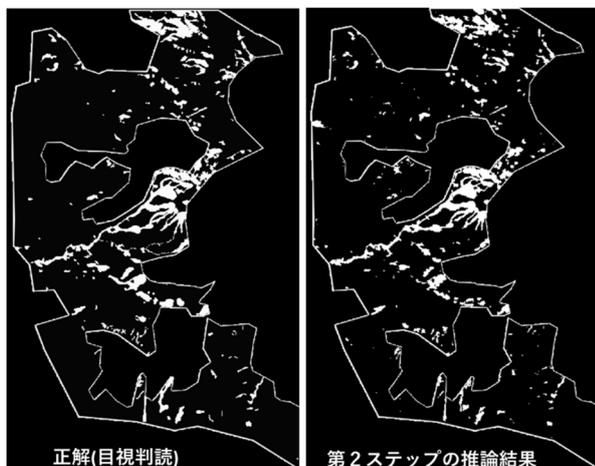


図-8 目視判読と推論結果の比較（阿蘇地域）

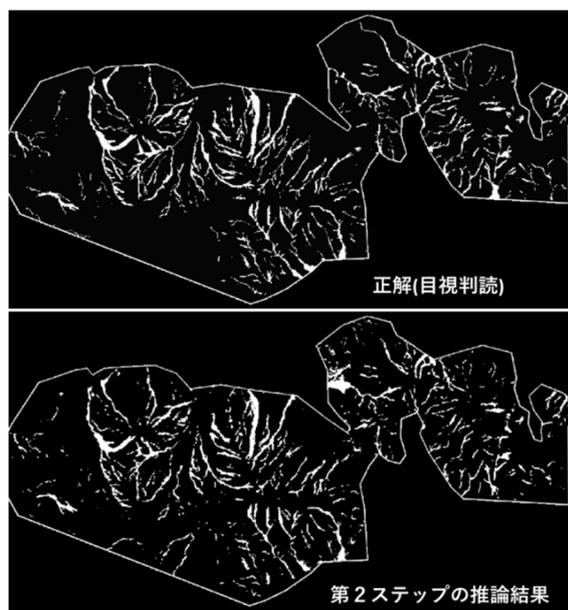


図-9 目視判読と推論結果の比較（広島地域）

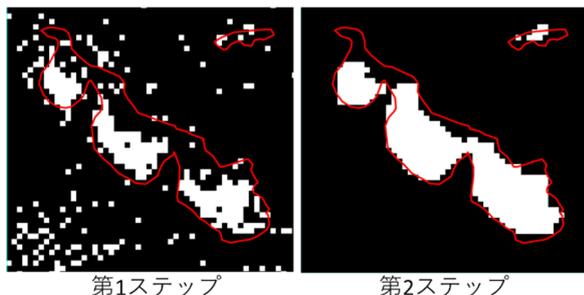


図-10 第 1 ステップと第 2 ステップの比較（阿蘇地域、拡大図）

の減少に留まったため、再現率もわずかな改善に留まった。第 2 ステップでは適合率と再現率が同程度の値を示し、IoU が 0.611 と比較的高い値を示していることから、誤検出と検出漏れのいずれかに偏ることなくバランスの良いモデルであると評価できる。

表-4 の生産土砂量の誤差率はいずれもマイナス値すなわち過小評価を示しており、第 2 ステップの方がより過小評価となっている。この理由は、検出漏れピクセルに対応して土砂量の過小評価が発生するが、第 1 ステップではノイズ状の誤検出ピクセルに対応した土砂量を「誤って」計上することで、過小評価幅を補っていたものと考えられる。しかし第 2 ステップにおいても 3 割程度の過小評価に収まっており、土砂災害発生後の迅速さを優先した概算土砂量把握という目的には十分な精度であると考えられる。

一方で堆積土砂量の誤差率は数百%と非常に大きく、概算土砂量としても許容できるレベルではない。この原因としては、誤検出ピクセルや、そうでなく正しく土砂移動を検出できていても崩壊地縁辺部や地すべり土塊内など立木が残留しているピクセルでは、樹高が堆積土砂として計上されて大きな誤差につながっているためと考えられる。

表-3 第 1 ステップ/第 2 ステップの混同行列

推論結果	正解	
	土砂移動あり	土砂移動なし
土砂移動あり	50,034 / 50,260	19,450 / 18,871
土砂移動なし	63,689 / 13,102	617,115 / 658,258

表-4 精度評価指標値の算出結果

		第 1 ステップ	第 2 ステップ
土砂移動 域	正解率	0.889	0.957
	適合率	0.440	0.793
	再現率	0.720	0.727
	IoU	0.376	0.611
土砂量の 誤差率	生産土砂	-23%	-34%
	堆積土砂	517%	299%

表-5 両地域における精度評価指標値の比較

		阿蘇地域	広島地域
土砂移動 域	正解率	0.959	0.954
	適合率	0.824	0.763
	再現率	0.714	0.741
	IoU	0.620	0.602
生産土砂量の誤差率		-39%	-27%

(2) 両地域による精度の比較

阿蘇地域と広島地域の精度評価指標値を表-5 に示す。ただし上述のとおり堆積土砂量については誤差が大きすぎて比較の意味がないので記していない。

土砂移動域に関する指標値については、概して両地域で大きな差はない。適合率で広島地域の方がやや低い値を示すのは、伐採地を誤検出したためである。一方で生産土砂量の誤差率は阿蘇地域-39%、広島地域で-27%と顕著な差が見られる。この理由は阿蘇地域では地震に起因した地すべり性の崩壊が多く、土砂生産域に立木・倒木が多く残存しており、災害後 DSM の標高が地盤高よりも高めに表現されているため、侵食深が過小評価された結果であると考えられる。

(3) 時間短縮効果

国土交通省の測量業務標準歩掛（令和5年度版）を基に計算すると、図-2の範囲（阿蘇地域・広島地域とも20~30km²程度）のグラウンドデータ作成には5人で5日~7日程度要することになる。さらに本研究において時間計測しながら土砂移動域の目視判読を再度行ったところ、阿蘇地域・広島地域それぞれ2日程度を要した。よって従来手法ではオリジナルデータ完成から土砂移動域把握までに7日~9日程度を要することになる。

一方で本研究ではGPU（NVIDIA Tesla M60）搭載の仮想デスクトップ環境で解析した場合、第1ステップ・第2ステップそれぞれ数分で推論は完了した。入力データの作成や推論結果の整理等を含めても1日で完了することができる。

(4) 地震による地盤変動の影響

阿蘇地域については地震による地盤変動のため、土砂移動が発生していなくとも数十cm程度の標高変化は普遍的に見られる。本研究ではこれに対する特別な処理は行っていないが、それでも一定の精度が得られたのは、主に樹林消失による標高変化によって土砂移動を検出するモデルとしたためであると考えている。

5. おわりに

樹林部を対象とし、災害前LPデータと、災害後LPデータのオリジナルデータのみを使用し、AIによって迅速に土砂移動域と生産土砂量を検出する手法を開発した。AIの手法としてはDNNとCNNの2ステップを行う点が特長である。得られた結果は下記の通りである。

- 正解率 0.957, 適合率 0.793, 再現率 0.727, IoU 0.611 という高精度でバランスの良い推論モデルを構築できた。ただし学習・検証領域を含んだ指標値であるため、それ以外の領域で汎用性を確認することが、今後の課題である。
- 推論結果を基に生産土砂量を推定した場合、誤差率は3割前後の過小評価に留まり、概算土砂量としては実用的な範囲であった。地震による土砂移動においては、豪雨による土砂移動よりも過小評価幅が大きめに出たが、これは立木が残存しているためと考えられる。
- 一方で堆積土砂量については数百%の誤差率が生じるため実用的でない。
- 開発した手法では、災害後LPのフィルタリング工程と土砂移動域の目視判読工程を不要とすることにより、対象面積20km²~30km²の場合、従来手法では7日~9日要していたところを1日に短縮できることができる。

謝辞：本研究では国土交通省九州地方整備局、林野庁森林整備部治山課、及び広島県土木部から貸与されたLPを使用した。ここに記し感謝いたします。

参考文献

- 1) 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，国総研資料第1110号，pp.43-45，2020
- 2) 国土地理院：斜面崩壊・堆積分布図，令和6年(2024年)能登半島地震に関する情報，https://www.gsi.go.jp/BOUSAI/20240101_noto_earthquake.html#6-2，2024.5.23
- 3) 広島大学平成30年7月豪雨災害調査団（地理学グループ）：平成30年7月豪雨による広島県の斜面崩壊の詳細分布図（第二報：最終報告），2019年6月27日，https://www.ajg.or.jp/disaster/files/201807_report008.pdf，2024.5.21
- 4) SAGA-GIS Module Library Documentation (v2.1.3)，https://saga-gis.sourceforge.io/saga_tool_doc/2.1.3/ta_morphometry_7.html，2024.5.19
- 5) Yokoyama, R., Shirasawa, M. and Richard, J., P.: Visualizing Topography by Openness: A New Application of Image Processing to Digital Elevation Models, Photogrammetric Engineering and Remote Sensing(68), No.3, pp.257-266, 2002

(2024.5.31 受付)