

深層学習 AI モデルによる SAR 衛星画像からの土砂移動箇所の自動判読

株式会社パスコ ○柴山卓史, 飯田久美, 杉本惇, 森田保成, 寶楽裕, 三富創, 下村博之, 吉川和男

1. はじめに

IPCC 報告書¹⁾では、今世紀末までに極端な降水がより強く、より頻繁になる可能性が非常に高いと予測されている。近年国内でも平成 29 年 7 月九州北部豪雨、平成 30 年 7 月豪雨、令和元年東日本台風（台風第 19 号）等の広域かつ激甚な土砂災害が頻発している。

広域の土砂災害を対象とする場合、地球観測衛星を用いることが有効と考えられる。とくに合成開口レーダ（SAR）を用いることで、天候に左右されることなく、また、夜間であっても被災地の状況把握が可能である。しかしながら、SAR 画像の目視判読には専門性が必要であり、技術者が限られるため、被害が広域に及ぶと、土砂移動発生箇所を目視判読あるいは画像解析により抽出するために時間を要する場合がある。

そこで、衛星 SAR データから被災状況の迅速に把握するため、近年発展が目覚ましい人工知能（AI）技術を活用することが有効と考えられる。本稿では ALOS-2 観測データから土砂移動発生箇所を抽出する AI 判読モデルの構築、および同モデルを近年の大規模な土砂災害に適用して精度検証した結果を報告する。

2. 対象の選定

2.1 対象地域の選定

SAR 画像による土砂移動発生箇所の AI 判読モデルを構築するためには、多くの教師データが必要である。そのため、近年、大規模な土砂災害が発生した九州北部および広島県南部を対象地域とした。土砂移動箇所の特定は、国土地理院による「平成 29 年 7 月九州北部豪雨に伴う被害状況判読図」²⁾（土砂崩壊地 1,935 箇所）、広島大学平成 30 年 7 月豪雨災害調査団（地理学グループ）による「広島県の斜面崩壊分布図」³⁾（斜面崩壊 11,581 箇所）を参考に行った。

2.2 対象画像の選定

各災害について、災害前後の観測がなされており、かつ 1 ピクセルが 3 m 程度と空間分解能の高い ALOS-2 画像を選定した。発災前の画像は、発災の直近の画像とした。当該地域は積雪がないことを確認し、特に季節は考慮しなかった。また、SAR 画像で土砂移動箇所を判読する場合は、SAR 衛星の観測方向に影響を受けることを考慮して、異なる撮影方向の画像を選定した。使用した画像を表-1 に示す。また、画像全体と土砂災害発生箇所の重ね合わせ図を図-1 に示す。

表-1 使用した ALOS-2 画像データの諸元

平成 29 年 7 月九州北部豪雨（九州北部）		
発災前	2016/04/29	ディセンディング,左側観測
発災後	2017/07/07	測,オフナディア角 29.1 度
平成 30 年 7 月豪雨災害（広島県南部）		
発災前	2018/03/17	アセンディング,右側観測
発災後	2018/07/21	オフナディア角,32.4 度

3. 教師データの作成

AI に学習させる教師データは、二時期の SAR 強度画像から土砂移動箇所を目視判読して作成した。この際、先述した既存の判読結果を参照し、オルソ幾何補正前のレーダ座標の SAR 画像を用いた。土砂移動箇所の範囲（ポリゴン）は地理座標（地形図）で作成した。判読にあたっては、SAR 画像の撮影方向と地形情報からレーダの届かない地域をあらかじめ不可視（シャドウ）領域として判読の対象外とした。教師データの作成結果を図-1、図-2 に示す。なお、図中の黄色が SAR 画像で判読出来た土砂移動箇所として教師データである。このうち青いメッシュ内に含まれる教師データを学習用とし、赤いメッシュは評価用とした。




図-1 九州北部

図-2 広島県南部

SAR 画像から判読した結果と既存の判読結果との比較を行ったところ、SAR 画像で判読できた土砂移動箇所数（ポリゴン数）は、既存の判読結果に示されるポリゴン数よりも少なかった。面積が 500 m² 未満になると SAR 画像による土砂移動箇所の抽出は困難であったことが分かる（図-3）。この結果は既往の報告⁴⁾とも整合的である。




図-3 土砂移動判読結果の規模

4. 構築した AI 判読モデルの概要

深層学習によるセマンティックセグメンテーション手法を用いて土砂移動域を検出する AI 判読モデルを構築した。セグメンテーション手法は領域分割とも呼ばれ、画像中の全ての画素に対してラベル付け（分類）を行う処理である。学習にあたっては、①二時期 SAR 強度オルソ画像、②地形（傾斜）データ、③Topographic Position Index (TPI) からなる地形画像情報に対し、セマンティックセグメンテーション手法の 1 つである U-Net をもとにアテンションマスクを取り入れた深層学習モデルとした。なお、アテンションマスクとは、入力データのどの部分に注意を向けるのかを指示する確率マスク画像である。SAR 衛星画像は観測方向や入射角により視認性（倒れ込み等の画像の歪み方）が大きく異なる。今回は教師データの観測条件が限られるため、軌道ごとに別々に学習を行ってモデルを構築した。




図-4 AI による結果（広島県南部の評価地域の一部）

5. 評価と考察

評価にあたっては、学習に使用していない土砂災害発生箇所に対して、2 シーンそれぞれで AI 判読を実施し、目視判読結果との比較により精度を算出した。AI 判読結果から閾値を設定し、ポリゴン化を行い判読により作成した土砂移動箇所ポリゴンとの重なり具合による割合を用いて、適合率 (Precision) と再現率 (Recall) を指標とした (図-5)。評価結果を表-2 に示す。




図-5 評価指標

$$\text{適合率 (Precision)} = \frac{A}{A + B} \quad \dots (1)$$

$$\text{再現率 (Recall)} = \frac{A}{A + C} \quad \dots (2)$$

表-2 評価結果

対象とした災害事例	適合率 Precision	再現率 Recall
九州北部	48.4%	22.7%
広島県南部	60.2%	50.4%

6. おわりに

広域に土砂災害が発生している場合を想定して、発生の有無や規模を迅速に把握する手法として、SAR 画像から AI により自動判読を行う手法を検討した。

AI により判読された土砂移動箇所の面積で判読精度を評価すると、再現率 (Recall) よりも適合率 (Precision) が高い結果となった。土砂移動箇所が広域に及ぶと想定される場合、SAR 画像全体から土砂移動現象が発生している可能性がある箇所を網羅的に概査し、現地点検の候補箇所として活用することが考えられる。そのため漏れなく抽出するために再現率 (Recall) を重視するとともに、面積比による評価ではなく、箇所による評価も検討する必要がある。今後は、観測条件の数を増やして汎化性能を高めつつ、精度や利便性を考えてモデルの検討を進め、社会実装に向けて自動判読モデルを改良する予定である。

謝辞：

本稿で述べた AI 判読モデル開発のうち、教師データ作成および精度評価・検証は、戦略的イノベーション創造プログラム (SIP) 「国家レジリエンス (防災・減災) の強化」、AI 判読モデルの高度化は「高圧ガス等技術基準策定研究開発事業 (停電復旧見通しの精緻化・情報共有システム等整備事業)」においてそれぞれ実施した。また、計算環境に産業技術総合研究所の AI 橋渡しクラウド (ABCI) を用いた。ここに記して謝意を表す。

参考文献

- 1) Intergovernmental Panel on Climate Change (2022): Climate Change 2022: Impacts, Adaptation and Vulnerability
- 2) 国土交通省国土地理院 (2017) : 平成 29 年 7 月九州北部豪雨に伴う被害状況判読図, 国土地理院技術資料 D1-No.873
- 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) (2019) : 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
- 4) 山下久美子・神山嬢子・鈴木大和・野呂智之・杉本惇・柴山卓史・鶴殿 俊昭 (2019) : 二時期 SAR 強度画像を用いた土砂移動箇所判読精度の検証—平成 29 年 7 月九州北部豪雨の事例—, 砂防学会誌, Vol. 71, No. 6, p. 21-27
- 5) Weiss, A. (2001): Topographic Position and Landforms Analysis, Poster Presentation, ESRI Users Conference, San Diego, CA