

災害対応時の土砂崩壊箇所判読における深層学習技術の導入

実施期間

令和 6 年度～令和 7 年度

応用地理部地理調査課

白石 喬久 中埜 貴元

牧野 奈那

1. はじめに

近年、大規模地震や集中豪雨により、広範囲に多数の土砂崩壊が発生する事例が発生している。国土地理院では、空中写真の正射画像を用いて土砂崩壊範囲を判読し、斜面崩壊・堆積分布図として関係機関へ提供してきた。しかし、目視による判読作業は労働集約的であり、広域である場合や崩壊箇所が多数に及ぶ場合、多くの時間と人手を要するという課題があった。

このような課題を踏まえ、国土地理院では災害対応時の判読作業を支援するため、深層学習技術を活用した土砂崩壊箇所抽出 AI（深層学習モデル）及び AI による抽出を行うツール（以下「本ツール」という。）の開発を実施した。

本ツールは、目視判読を代替することを目的とするものではなく、AI により土砂崩壊の可能性が高い箇所を先行的に抽出することで、災害対応時における判読作業全体の効率化と精度向上を図ることを目的としている。災害対応の初期段階において、スクリーニング（下読み作業）を AI により実施することで、判読者が重点的に確認すべき区域を早期に把握できるようにする。

AI によって崩壊候補箇所を事前に抽出・可視化することで、崩壊が集中している区域や判読の優先度の高い範囲を明確にし、これらの区域に重点的に人員を配置することが可能となる。その結果、判読作業全体に要する時間の短縮に加え、判読漏れの低減による判読精度の向上を図るものである。

実際の災害対応時には、このスクリーニングを正射画像の到着直後に実施し、土砂崩壊範囲の判読や成果の点検を行う担当者へ共有することを想定している。

2. AI 技術の概要と判読手法

2.1 使用する AI 技術の概要

本ツールでは、土砂崩壊箇所の抽出用 AI として、画像認識分野で広く利用され、高い分類精度を持つ Resnet50（He et al., 2016）に基づいて構成した多クラス分類モデルを採用した。

本ツールでは、抽出の対象となる正射画像（航空カメラ撮影、地上画素寸法 0.2 m）は、25 m 四方のグリッド（125×125 px）に分割され、AI によって各グリッドについて「崩壊あり」「崩壊なし」「雲」「濁水」の 4 クラスに分類される（図-1）。これにより、広域の画像を効率的に処理し、崩壊が疑われる箇所を抽出することが可能となっている（図-2）。




図-1 25 m グリッドに分割した画像の例（4 クラス）




図-2 25 m グリッド単位の土砂崩壊箇所抽出のイメージ（背景の正射画像は平成 30 年 7 月豪雨より）

2.2 AI の学習データ

AI の学習には、東北地方太平洋沖地震，平成 30 年 7 月豪雨，令和 6 年能登半島地震など，8 種類の災害事例（表-1）の正射画像を目視判読し作成した，25 m グリッド単位のラベル付き画像約 14.5 万枚を使用した（表-2）．様々なタイプの災害を学習させることで，将来発生する多様な災害への適用を想定している．

表-1 AI の学習に使用した過去の災害事例の一覧

発生年	災害名
平成 23 年（2011 年）	平成 23 年東北地方太平洋沖地震
平成 28 年（2016 年）	熊本地震
平成 29 年（2017 年）	九州北部豪雨
平成 30 年（2018 年）	7 月豪雨
平成 30 年（2018 年）	北海道胆振東部地震
令和元年（2019 年）	東日本台風
令和 6 年（2024 年）	能登半島地震
令和 6 年（2024 年）	9 月 20 日からの大雨

表-2 AI の学習用データ，テスト用データの内訳

ラベル	学習用データ（枚）	テスト用データ（枚）
崩壊あり	36,120	8,990
崩壊なし	86,840	21,608
雲	16,137	4,033
濁水	5,640	1,384
計	144,737	36,015

2.3 AI の性能評価

AI の抽出性能は，土砂崩壊箇所の抽出漏れの少なさを表す Recall（網羅性），AI の抽出結果の正確

性を評価する Precision（正確性），及び両者のバランスを評価する F 値を指標として評価している．

8 災害，約 3.6 万枚のテスト用データを用いた検証の結果，Recall が 0.942，Precision が 0.799，F 値 0.864 となった．

Recall が高いことから崩壊箇所の見逃しが少ないことが確認された．また F 値についても，機械学習・画像処理分野において一般に高い抽出精度や実用性の目安とされる F 値 0.8 を上回る結果が得られたことから，災害対応実務に耐え得る性能を有していることが示唆された．

2.4 精度向上のための処理

AI の抽出結果に対しては，既存の地形分類データ（例えば Iwahashi, 2025），水部データ，傾斜量データを用いたマスク処理を行い，土砂崩壊発生リスクの低い範囲を除外している．また，画像処理による最適化処理（誤抽出された小規模な崩壊箇所の除去のためのオープニング処理，崩壊箇所・雲の範囲内の隙間を補完するためのクロージング処理，面積の小さいグリッド塊を削除する処理）を組み合わせることで，誤抽出の低減と抽出精度の向上を図っている．マスク処理，最適化処理は処理実施の可否，種類を状況に応じて設定可能である．

3. 適用事例

本ツールを過去の災害時に撮影された正射画像に対して適用した事例について述べる．

3.1 平成 30 年北海道胆振東部地震に対する適用

今回は平成 30 年 9 月 6 日の北海道胆振東部地震の発災後，当日に厚真川地区で撮影された正射画像（約 193 km²）を用いた．本ツールでは，画像データの準備・ツールの設定・ツールによる処理を含めて約 30 分で，数値データ（GeoJSON 形式）及びラスタタイルを出力した．この処理時間は，土砂崩壊判読作業の初期において実用的な処理速度を確保していることを示す（図-3）．




図-3 ツールの処理手順

厚真川地区の判読範囲全体の目視判読と AI 抽出の結果を図-4 に示す．AI の抽出結果において，目視判読結果と整合的に土砂崩壊の範囲と雲の範囲を抽出していることが確認できる．




図-4 厚真川地区の土砂崩壊範囲 （左）：目視判読結果 （右）：AI による抽出結果

図-4 中の範囲 a を拡大した図を図-5 に示す．範囲 a では山地斜面の土砂崩壊と山間の平野に崩壊の堆積物が確認できる．AI による抽出結果においても，斜面崩壊と平野の堆積物の両方を目視判読結果と整合的に抽出できている．




図-5 土砂崩壊範囲の拡大図 (左): 目視判読結果 (右): AI による抽出結果

4. 結論

本論では，災害対応時における土砂崩壊箇所の迅速な把握と判読作業の効率化を目的として，深層学習技術を用いた土砂崩壊箇所抽出 AI 及び AI による抽出を行うツールの開発について述べた．正射画像を 25 m グリッド単位で分類する多クラス分類モデルを構築し，8 災害・約 14.5 万枚のラベル付き画像を用いて学習を行った結果，抽出精度を示す F 値は 0.864 に達し，実用段階の目安である 0.8 を上回る性能を確認した．

本ツールは，AI による抽出に加えて，地形分類や水部情報等を用いたマスク処理，画像処理による最適化を組み合わせることで，高精度かつ迅速な成果作成を可能としている．これにより，災害時の土砂崩壊判読作業における全体把握の迅速化や判読・点検作業の効率化に寄与する．

今後は，本論で構築した AI について，地上画素寸法の異なる正射画像（例えば一眼レフカメラで撮影した画像）に対応するための AI の学習・構築や，ハードウェアの維持管理について検討する．あわせて，災害対応訓練を通じた運用検証と継続的な改善を行い，災害対応実務における実運用を図りたい．

参考文献

- Iwahashi J. (2025): Depth to bedrock in Japan insights from borehole data and terrain analysis using digital elevation models. Progress in Earth and Planetary Science,12, 23. doi:10.1186/s40645-025-00698-3
- Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun (2016): Deep Residual Learning for Image Recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778. doi:10.1109/CVPR.2016.90