災害対応時の土砂崩壊箇所判読を支援する深層学習ツールの開発

DEVELOPMENT OF A DEEP LEARNING–BASED TOOL TO SUPPORT LANDSLIDE AREA INTERPRETATION IN DISASTER RESPONSE

白石 喬久[1]・中埜 貴元[2]・牧野 奈那[1]
Takahisa SHIRAISHI, Takayuki NAKANO and Nana MAKINO

[1]国土交通省国土地理院（〒305−0811 茨城県つくば市北郷 1 番）
E-mail: shiraishi-t96ti@mlit.go.jp，makino-n96bt@mlit.go.jp
[2]大正大学情報科学部（〒170−8470 東京都豊島区西巣鴨 3−20−1）
E-mail: t_nakano@mail.tais.ac.jp

***Key Words**: landslide, disaster response, deep learning, aerial imagery, interpretation support*

1. 背景と目的

近年，大規模な地震や集中豪雨に伴って，広範囲に土砂崩壊の発生する事例が日本各地で見られる．国土地理院では，被害の状況を把握するため，被災地域において空中写真の緊急撮影を実施し，撮影した空中写真から作成した正射画像を用いて土砂崩壊箇所を目視判読し，斜面崩壊・土石流・堆積分布図として関係機関へ提供してきた．しかし，被害が広域に及ぶ場合や崩壊箇所が多数存在する場合には，目視判読には多くの時間と人手を要し，迅速な被害把握が困難であった．

このような中，近年の深層学習技術の発達を背景に，空中写真を用いた深層学習による土砂崩壊箇所の検出に関する研究が報告されている．例えば，叶井ら[1)]は，正射画像に対して Mask R-CNN を用いたセマンティックセグメンテーションを適用し，土砂崩壊箇所を画素単位で自動的に検出する手法を提案した．その検出精度は F 値 0.771 であり，深層学習による抽出の有効性を示すものであるが，災害対応への適用においては実務上の運用条件を踏まえた検討が必要となる．

国土地理院が災害対応において提供する斜面崩壊・土石流・堆積分布図は，関係機関において被災箇所・規模の確認や復旧対策立案等に活用されるため，一定以上の情報の精度・確度が求められる．そのため，土砂崩壊箇所・堆積範囲の判読作業においては，現状では正確性等も考慮し，深層学習等により自動検出された結果をそのまま用いるのではなく，初動段階での判読作業を支援し，作業の迅速化・高精度化を図ることができる成果が望ましい．

本研究では，このような実務上の要求に着目し，災害対応時の土砂崩壊箇所の判読作業を支援することを目的に，深層学習モデルを用いた土砂崩壊箇所のスクリーニング手法について検討した．その結果として，深層学習技術を活用した土砂崩壊箇所抽出モデル（以下「深層学習モデル」という．）及びモデルによる抽出結果を可視化・共有するツール（以下「本ツール」という．）を開発した．本稿では，深層学習モデルの概要及び本ツールの構成を示すとともに，過去の災害事例への適用を通じて，災害対応における判読支援手法としての有用性について検証した結果を報告する．

本ツールは，目視判読を完全に代替することを目的とするものではなく，深層学習モデルにより土砂崩壊の可能性が高い箇所を先行的に抽出し，災害対応時の判読作業全体の効率化と精度向上を図るものである．災害対応における判読作業の初動段階では，

深層学習モデルにより土砂崩壊候補箇所を事前に抽出・可視化することで，土砂崩壊箇所が集中する区域や判読の優先度が高い範囲を把握でき，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．判読対象の優先順位が明確になることで全体として判読の精度向上にもつながると考えられる．実際の災害対応では，正射画像が完成次第，本スクリーニングを実施し，土砂崩壊箇所の判読や成果の点検を行う作業者と速やかに共有する運用を想定している．

2. 本ツールと深層学習モデルの構成

(1) 本ツールの構成

本研究では，空中写真から作成した正射画像から25m グリッド単位で土砂崩壊箇所を抽出するツールを構築した．ツール内の処理の手順を**図-1** に示す．

本ツールは，災害対応実務における判読支援への適用，具体的には学習コスト低減，抽出処理時間の短縮，及び土砂崩壊箇所の把握に十分な抽出粒度（抽出範囲の形状の詳細さや抽出密度）の確保を考慮し，より詳細な抽出が可能なセマンティックセグメンテーション手法ではなく，グリッドに分割した各画像に多クラス分類モデルを適用する手法を採用した．

(2) 使用する深層学習モデルの概要

本ツールでは，土砂崩壊箇所抽出用の深層学習モデルとして，画像認識分野で広く利用され，高い分類精度を持つ Resnet50[2]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 0.2m）を 25m 四方のグリッド（125px×125px）に分割し，深層学習モデルによって各分割画像を「崩壊あり」「崩壊なし」「雲」「濁水」の 4 クラスに分類する（**図-2**）．「崩壊あり」は 1 グリッドの面積のおおよそ 3 割以上を土砂崩壊箇所・堆積範囲として判読される範囲が占めるもの，「雲」及び「濁水」はグリッド面積のおおよそ 5 割以上をそれぞれ雲，濁水として判読される範囲が占めるもので，それら以外が「崩壊なし」に該当する．なお，「濁水」は斜面崩壊・土石流・堆積分布図において判読の対象としないが，豪雨災害の際には土石流などに伴う濁水の流出が見られること，また，濁水の湛水域が土砂崩壊箇所として誤判読されるケースが見られることから，これらの対応用として分類した．

(3) 深層学習モデルの学習用データ

深層学習モデルの学習には，平成 28 年熊本地震，

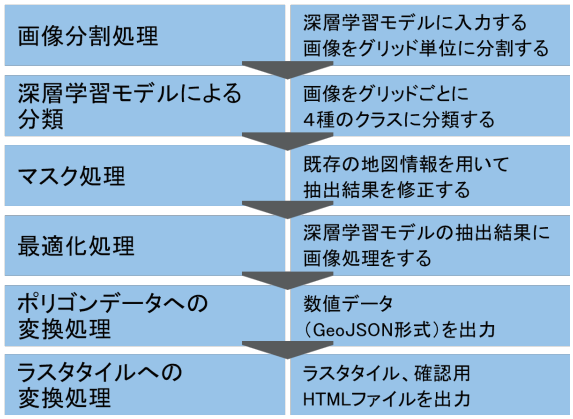


図-1　本ツールの処理手順

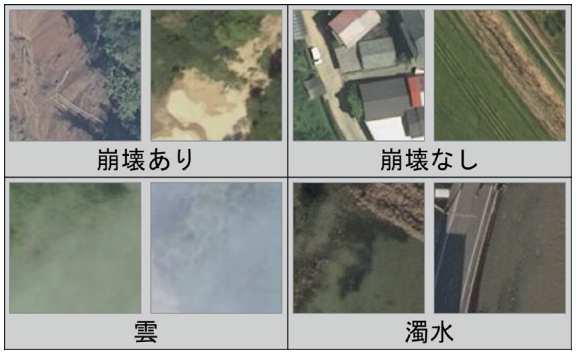


図-2　25m グリッドに分割した画像の例（4 クラス）

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，25m 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 左**）．様々な種類の災害を学習用データとすることで，将来発生する多様な災害に適用できるよう設計した．

(4) 深層学習モデルの性能評価

深層学習モデルの抽出性能は，土砂崩壊箇所の抽出漏れの少なさを表す Recall（網羅性），深層学習モデル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た．なお，各指標は「崩壊あり」クラスを対象に算出した．

学習用データに含まない，8 災害の約 3.6 万枚の検証用データ（**表-2 左**）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と言える．また F 値については，0.8 を上回る結果が得られたことから，本研究の土砂崩壊箇所のスクリーニング用途においては一定の有用性を示す結果であると考える．

(5) 抽出精度向上のための処理

深層学習モデルの抽出結果には，以下のような誤

表-1　深層学習モデルの学習・検証に使用した過去の災害事例の一覧

災害の発生年	災害名
平成 23 年　（2011 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　深層学習モデルの学習用データ及び検証用データの内訳数（左）と本ツールの実装環境（右）.

ラベル	学習用データ（枚）	検証用データ（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

構成	部品名・説明
CPU	Intel Xeon Silver 4416+
GPU	NVIDIA RTX4000 Ada Generation (20GB)
メモリ	128GB (DDR5, 16GB×8)
OS	Ubuntu Server 24.04.3
主なソフトウェア・ライブラリ	Python 3.10.14 torch 2.3.1 torchvision 0.18.1 GDAL 3.8.4

抽出・抽出不足が含まれる場合がある.

1) 土砂崩壊箇所が発生するリスクが低いと考えられる地形(例えば氾濫平野･海岸平野などの平坦地, 傾斜量の少ない場所，河川・ダム・海などの水面など）での「崩壊あり」クラスの誤抽出.

2) 該当しない場所に断続的に発生する「崩壊あり」や「雲」クラスの誤抽出．本来「崩壊あり」や「雲」クラスは連続的にグリッドが抽出されるが，断続的なノイズ状に誤抽出が発生する場合がある.

3) 本来連続している土砂崩壊箇所が，植生などにより隠されて抽出できていない抽出不足.

これらの誤抽出・抽出不足に対応するため，既往の地理空間情報を用いたマスク処理と画像処理による最適化処理を実装した.

土砂崩壊箇所の発生リスクが低い場所における「崩壊あり」クラスの誤抽出は，既存の地形分類データ（例えば 30m 解像度の DEM から作成した日本の地形分類データ [3]）や傾斜量データ，水部データを用いたマスク処理によって修正できる仕組みとしている.

該当しない場所に断続的に発生する「崩壊あり」や「雲」クラスのグリッドの誤抽出は，オープニング処理及び面積の小さいグリッド塊を削除する処理によって修正できる.

連続した土砂崩壊箇所が不連続になっている箇所については，クロージング処理により補間できる.

マスク処理，最適化処理は処理実施の可否や処理の種類を状況に応じて設定可能である．そのため，網羅性を重視する場合や誤抽出の低減を重視する場合など，深層学習モデルの抽出結果に応じて設定する想定である.

3. 過去の災害に対する適用事例

本ツールを過去の災害時に作成された正射画像に対して適用した事例について述べる．様々な災害や空中写真の撮影条件に対応可能かどうかを検証するため，以下の 3 種類の災害について検証を行った.

1) 地震災害の事例：平成 30 年北海道胆振東部地震
2) 豪雨災害の事例：平成 30 年 7 月豪雨
3) 一眼レフカメラで撮影した豪雨災害の事例 : 令和 7 年 8 月 6 日からの大雨

検証における本ツールの実装環境は**表-2 右**のとおりである.

(1) 平成 30 年北海道胆振東部地震に対する適用

対象の画像として, 平成 30 年北海道胆振東部地震後の平成 30 年 9 月 6 日に厚真川地区で撮影された空中写真の正射画像（約 193km^2）を用いた．本ツールでは，画像データの準備・ツールの設定までで 15 分，ツールによる処理に 15 分，計約 30 分で，数値データ（GeoJSON 形式）及びラスタタイルを出力できた．この処理時間は，実用的な処理速度を確保できていることを示す.

最適化処理では，クラス「崩壊あり」のグリッドに面積がグリッド 3 個以下の小さいグリッド塊を削除する処理，クラス「雲」のグリッドに面積がグリッド 1 個以下の小さいグリッド塊を削除する処理とクロージング処理，オープニング処理を適用した.

厚真川地区の判読範囲全体の目視判読結果（ポリゴン形式）と本ツールによる抽出結果を**図-3** に示す. 本ツールの抽出結果では，目視判読結果と整合的に土砂崩壊箇所と雲の範囲を抽出できていることが確認できる．**図-4**（**図-3** の範囲 a）では，山地斜面の土砂崩壊箇所と山間の平野部に流出した堆積物を大きな相違なく抽出できていることが分かる.

平成 30 年北海道胆振東部地震の事例において定性的に良好な抽出結果が得られた要因としては，裸地化した崩壊箇所と周辺の植生との間に明瞭な輝度・テクスチャの差が存在していたことが挙げられる．また，対象とした正射画像は，深層学習モデルの学習用データと同等の撮影方式及び地上画素寸法（0.2m）で作成されており，撮影条件の差異が少な

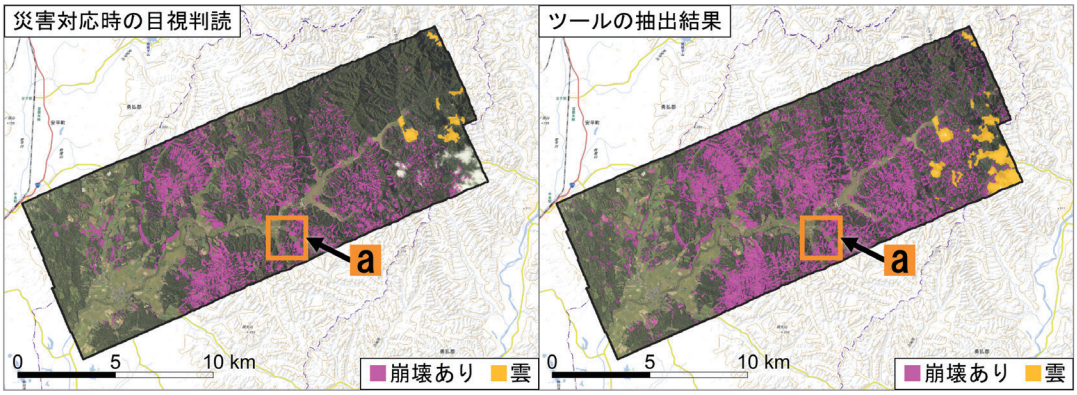


図-3　厚真川地区の土砂崩壊箇所．（左）目視判読結果，（右）ツールによる抽出結果．

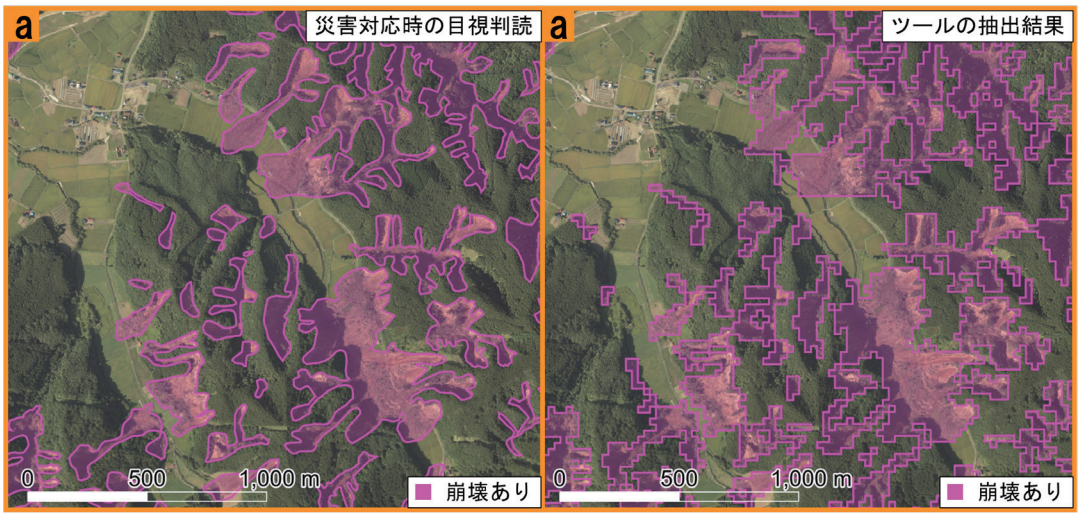


図-4　厚真川地区の土砂崩壊箇所（図-3 範囲 a）の拡大図．（左）目視判読結果，（右）ツールによる抽出結果．

かった．これらの条件が重なったことで，深層学習モデルが学習時に獲得した特徴表現を推論時に十分に活用できたものと推察される．

(2) 平成 30 年 7 月豪雨に対する適用

対象の画像として平成 30 年 7 月豪雨において，平成 30 年 7 月 13 日に呉東部地区で撮影された空中写真の正射画像（約 293km^2）を用いた．呉東部地区の災害対応時の判読では土砂崩壊箇所の判読について，崩壊箇所をポイント形式，雲が写っている範囲をポリゴン形式で取得している．崩壊箇所がポイントで取得されたのは，崩壊箇所が膨大であった中で，災害対応時に求められた時間内に成果を提供するためである．

最適化処理については，平成 30 年北海道胆振東部地震での設定を踏襲したが，豪雨に伴う崩壊は地震に比べて規模が小さいため，クラス「崩壊あり」の面積が小さいグリッド塊を削除する処理の閾値を 3 個以下から 1 個以下に変更した．呉東部地区の判読範囲全体の目視判読結果（崩壊箇所はポイント形式，雲はポリゴン形式）と本ツールの抽出の結果を図-5 に示す．崩壊箇所についてポイント形式とグリッド形式で表現は異なるものの，画像中央に崩壊箇所と雲が集中して分布することが確認できる．

図-6（図-5 の範囲 b）の災害対応時の目視判読では崩壊箇所をポイントで取得しているため，被害規模が直感的に分かりづらい．一方，ツールの抽出結果では崩壊範囲を面的に取得できており，崩壊範囲の把握が容易である．

しかし，ツールの抽出結果では画像上部の低地の範囲に雲の誤抽出が見られた．これは雲に近い特徴のテクスチャがある箇所を抽出していると考えられる．このような誤抽出箇所は 1 個のグリッド塊当たりの面積が小さいため，最適化処理で削除するグリッド塊のサイズの閾値を調整することで削除できる．ただし，それにより規模の小さな正しい抽出箇所も削除されてしまうため，注意が必要である．

(3) 令和 7 年 8 月 6 日からの大雨に対する適用

令和 7 年 8 月 6 日からの大雨において，令和 7 年 8 月 15 日に天草上島地区で撮影された空中写真の正射画像（約 459km^2）を用いた．当該画像は航空機内

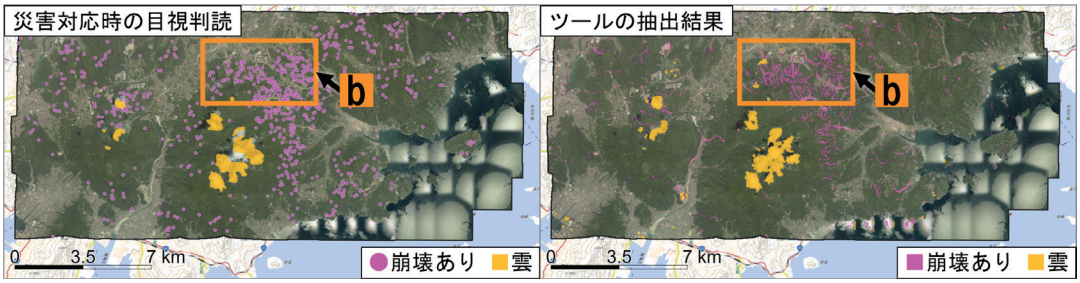


図-5　呉東部地区の土砂崩壊箇所．（左）目視判読結果，（右）ツールによる抽出結果．

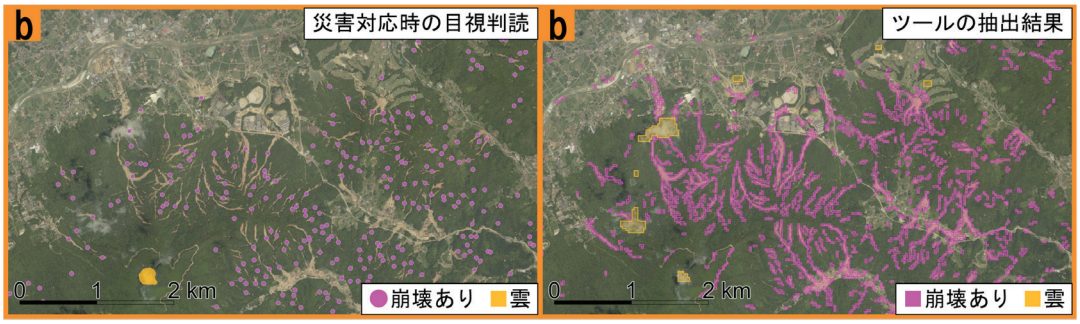


図-6　呉東部地区の土砂崩壊箇所（図-5 範囲 b）の拡大図．（左）目視判読結果，（右）ツールによる抽出結果．

から一眼レフカメラで撮影された写真を基に作成されており，地上画素寸法は 0.4m と，学習用データに用いた正射画像（同 0.2m）とは異なる．

本ツールの仕様により，グリッドサイズを 25m から 20m に変更して処理を実行し，最適化処理については平成 30 年 7 月豪雨と同様の設定とした．

図-7 に示す抽出結果では，海域や一部裸地において土砂崩壊箇所及び雲の誤抽出が顕著であった一方，山地斜面に発生した比較的規模の大きい崩壊については，**図-8** に示すように目視判読結果と整合的な抽出が得られた箇所も確認できた．しかし，**図-9** に示すように庭園路を土砂崩壊箇所，河川水面を雲と誤抽出する事例も多く，本事例では平成 30 年北海道胆振東部地震や平成 30 年 7 月豪雨と比較して，土砂崩壊箇所・雲の誤抽出が全体として多く見られた．この原因として以下の点が考えられる．

1) 深層学習モデルの学習用データに使用した画像と推論対象とした画像の撮影条件が異なる．例えば，学習用データの画像は航空機カメラで撮影した画像（地上画素寸法 0.2m），推論対象とした画像は航空機の機内から一眼レフカメラで撮影した画像（地上画素寸法 0.4m）．そのほか，カメラ性能，撮影条件などが異なるため，学習用データとの間に差異が発生し，分類結果に影響を与えた可能性がある．

2) 推論時の 1 グリッド当たりの画素数が学習用データと比較して少ない．学習用データの正射画像は地上画素寸法 0.2m で，25m 四方のグリッド（125px×125px）から構成されている．一方，推論時の 1 グリッドのサイズは地上画素寸法 0.4m で，20m 四方のグリッド（50px×50px）である．このように，学習用データと比較して 1 画像当たりの画素数・情報量が少なくなっている．この不一致が，深層学習モデルが学習時に獲得した特徴表現を十分に活用できない要因となり，分類精度に影響を及ぼした可能性が示唆される．

(4) 3 種類の適用事例に関する横断的な考察

3 種類の適用事例を比較すると，本ツールは学習用データと同等の撮影方式及び地上画素寸法で取得された正射画像を用いた場合には有効に機能し，土砂崩壊箇所と周辺地物との視覚的差異が明瞭な場合に安定した抽出結果が得られることが確認できた．

一方，誤抽出が増加する条件としては，撮影方式や地上画素寸法が学習用データと大きく異なる場合や，ハレーションにより白くなった海面や土砂崩壊箇所と同様の土色を示す裸地など，雲や土砂崩壊箇所と類似した特徴を持つ被覆が広範囲に分布する場合が考えられる．

以上より，本ツールの適用可否を判断する際には，正射画像の地上画素寸法や撮影条件といった画像特性を考慮した上で，抽出結果の妥当性を確認し，限定的に使用する，もしくは使用を見送る判断も必要だと考える．

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，25m グ

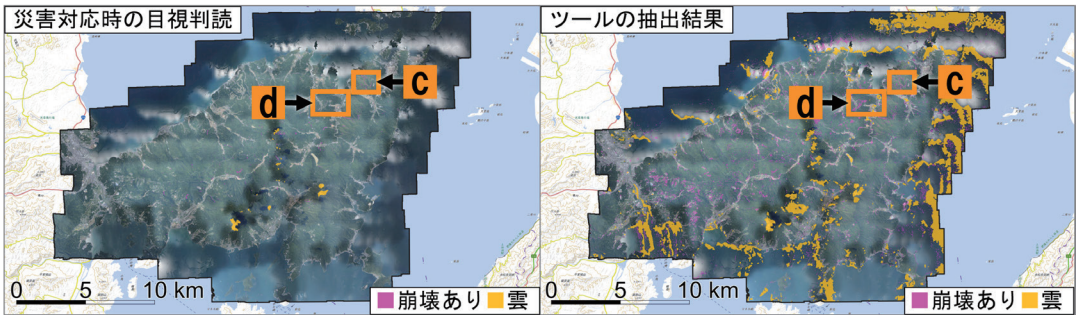


図-7　天草上島地区の土砂崩壊箇所．（左）目視判読結果，（右）ツールによる抽出結果．

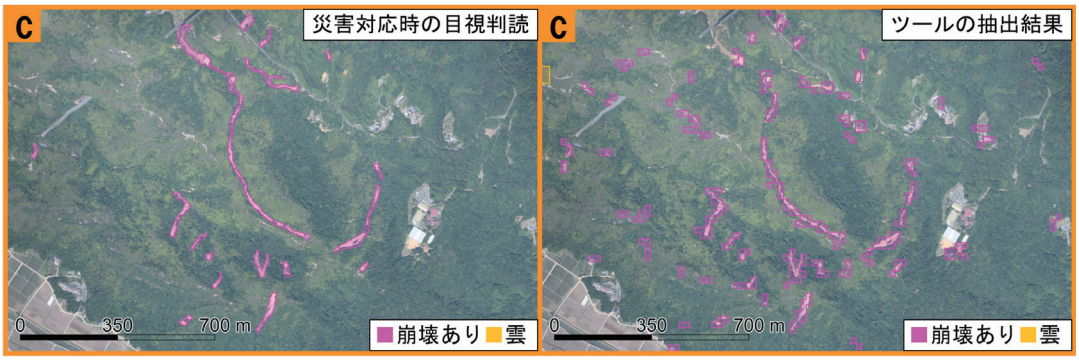


図-8　天草上島地区の土砂崩壊箇所（図-7 範囲 c）の拡大図．（左）目視判読結果，（右）ツールによる抽出結果．

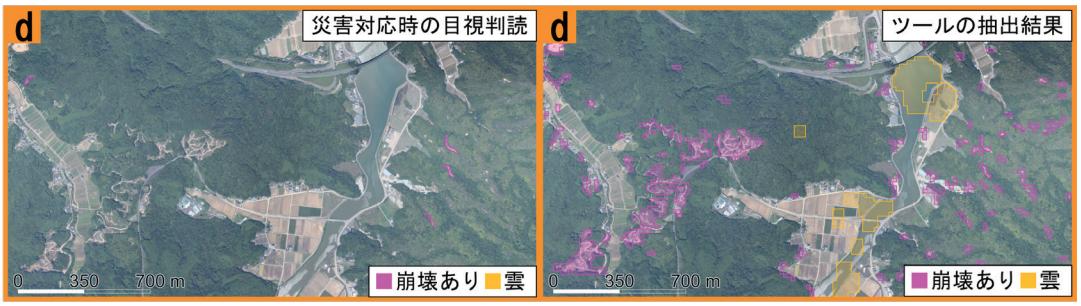


図-9　天草上島地区の土砂崩壊箇所（図-7 範囲 d）の拡大図．（左）目視判読結果，（右）ツールによる抽出結果．

リッド単位で正射画像を分類する多クラス分類型の深層学習モデル，及びその抽出結果を使用した判読支援ツールを開発した．

8 災害・約 14.5 万枚のラベル付き画像を用いた学習及び評価の結果，F 値 0.864 の性能を確認するとともに，マスク処理や最適化処理を組み合わせることで，災害対応初動におけるスクリーニング用途として実務に有効であることを示した．撮影条件が学習用データと整合する場合には安定した抽出結果が得られる一方，条件が異なる場合には誤抽出が増加することから，現状では，本ツールは人による確認を前提とした判読支援技術として災害対応時の判読作業に使用することが有効であると考えられる．

適用事例の検証により，地上画素寸法や撮影方式が学習用データと大きく異なる場合には誤抽出が多く見られた．このことから今後は，撮影条件の違いを考慮した学習用データの拡充やモデルの改良を進めると共に，災害対応訓練や実運用を通じた検証と継続的な調整を行うことで，災害対応実務における判読支援技術としての実用性と判断に資する信頼性の向上を図る必要がある．

参考文献

1)　叶井和樹，久保栞，山根達郎，全邦釘：Mask R-CNN による航空写真からの土砂崩壊地自動検出手法，AI・データサイエンス論文集，2 (J2), pp. 223-231, 2021.

2)　Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun: Deep Residual Learning for Image Recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778, 2016.

3)　Iwahashi J.: 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, 2025.

（2026. 5. 29　受付）