

## 航空撮影画像からの画像認識技術による斜面崩壊領域検出の検討

内山庄一郎\*・中西良成\*\*

### Using Aerial Imagery to Detect Slope Failure Areas

Shoichiro UCHIYAMA\* and Yoshinari NAKANISHI\*\*

*\*Multi-hazard Risk Assessment Research Division,  
National Research Institute for Earth Science and Disaster Resilience, Japan  
uchiyama@bosai.go.jp*

*\*\*Kozo Keikaku Engineering Inc, Japan  
nakanisi@kke.co.jp*

#### Abstract

We studied the utility of image recognition technology for detecting slope failure areas from aerial imagery by using Mask R-CNN (Region-based Convolutional Neural Network), which is a kind of image segmentation. In addition, aerial imagery (orthoimagery) and slope failure area data from a torrential rain event in 2018 in western Japan was used. To improve accuracy, treating imbalanced training data was considered because of its high probability in the case of data for slope failure areas detection. We confirmed that the loss calculation weighting according to the area ratio of the slope failure areas was effective in improving accuracy. The F-value for the detection accuracy of Mask R-CNN with weighted loss was 0.68.

**Key words:** Slope failure, Image segmentation, Mask R-CNN (Region-based Convolutional Neural Network)

#### 1. はじめに

近年、気候変動に伴い線状降水帯の発生や台風の大規模化などにより、水害・土砂災害が激甚化とともに広域化し、毎年のように大きな被害が生じている。

大規模災害が発生した場合、初動対応として、災害の全体像を把握し、限られた救助部隊を被害の最も大きな地域に配分し、効率的・効果的な救助活動を行うことが重要である。しかし、災害の初期段階において、迅速に災害の全体像を把握する手法については、未だ確立されていないのが現状である。一方、災害の全体像を把握する手法の1つとして、斜面崩壊分布図があるが、この分布図は航空撮影画像を目視で確認しながら作成されるため、多大な時間と労力を要する。例えば、平成16年新潟県中越地

震のケースでは、専門家2名により約3年(大八木ほか, 2008)、平成30年7月豪雨のケースでは3名の専門家を含む10名程度のチームで、第1報作成まで約2週間(広島大学平成30年7月豪雨災害調査団(地理学グループ), 2018)、最終報告作成までに約1年を要している(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)。これらのことから、現状では、災害直後に航空撮影画像を人間が目視で確認することにより、迅速に災害の全体像を把握することは困難であると考えられる。

そこで、災害初期に迅速に災害の全体像を把握し、初動対応に有用な情報を提供することを目的として、航空撮影画像に対する画像認識技術(AI技術)による斜面崩壊領域の検出手法について、その適用

\* 国立研究開発法人 防災科学技術研究所 マルチハザードリスク評価研究部門

\*\* 株式会社 構造計画研究所 IoE ビジネス部

の可能性も含めて研究を行った。本稿はその検討結果を報告するものである。

## 2. 画像認識技術

### 2.1 画像認識技術(深層学習)

近年の AI 技術の発展は著しく、様々な分野で活用されている。中でも画像認識技術は、第3次 AI ブームの初期から深層学習(Deep Learning)を中心に研究が進められ顔や車など明確な対象物の認識では、非常に高い精度を実現している。更には画像としての特徴が曖昧な、人間でも判断が難しい対象(例えばレントゲン写真から癌を見つけるなど)の認識も可能になっている(Sakai, Y. *et al.*, 2018)。

深層学習とは機械学習手法の1つであり、人間の神経細胞の仕組みを模倣した多層構造のニューラルネットワークを用いる手法である。深層学習はこの多層ニューラルネットワークにより認識対象の判断に必要な特徴を自動選定し学習するものである。従来の特徴の選別に人間が多大な労力を費やしていたものに比べ、深層学習の登場はその後の精度向上や対応する課題の拡大を一気に進めた。

検出したい斜面崩壊領域は不定形な領域であるため、画像内の各画素が認識対象であるか否かを判定する image segmentation 技術を用いることとした。採用した具体的な手法は Mask R-CNN (Region-Based Convolutional Neural Network) である。

### 2.2 Mask R-CNN

Mask R-CNN は 2017 年に He, K. *et al.* (2017) により提案された一般物体認識と instance segmentation を同時に行うマルチタスクの物体認識手法である。一般物体認識とは、画像内に含まれる対象物体の位置とカテゴリを認識するタスクのことであり、対象物体の位置は対象物体に外接する矩形として認識される。instance segmentation とは image segmentation の一種であり、画素単位で対象物体の位置を認識するとともに、隣接する対象物体を個別別に認識するタスクである。

### 2.3 斜面崩壊領域検出の既往研究

航空撮影画像からの斜面崩壊領域検出に関しては様々な研究が実施されている。河村らは、image segmentation の1つである深層学習モデル U-Net を採用し、航空撮影画像からの土砂移動分布図作成の効率化、自動化手法を提案している(河村ほか、

2018)。また画像分類を image segmentation に組み合わせる手法の有効性を示している。

本研究で採用した Mask R-CNN を用いた斜面崩壊領域の自動検出に関する研究としては、叶井らの研究がある(叶井ほか, 2020 ; 叶井ほか, 2021)。叶井らの研究では、平成 29 年 7 月九州北部豪雨、平成 30 年 7 月豪雨、平成 30 年 9 月北海道地震などの斜面崩壊領域の航空写真を用い、Mask R-CNN の斜面崩壊領域検出への適用可能性を確認している。

本研究は、叶井らと同様に Mask R-CNN の斜面崩壊領域検出への適用可能性の検証を行ったものである。また、現場での活用時に想定される斜面崩壊領域を含まない領域を広範に含む航空撮影画像も含めることにより、精度検証と精度向上策の検討についても併せて行った。

## 3. 使用データおよび機材

本研究で使用したデータは、平成 30 年 7 月豪雨災害発生直後の広島地域の航空撮影画像(地理院地図(<https://cyberjapandata.gis.go.jp>)のオルソ画像)および斜面崩壊領域定義データである。航空撮影画像のサイズは 2,500×1,875 画素であり、分解能は 80 cm/画素である。また斜面崩壊領域定義データは専門家が判定した結果であり、斜面崩壊領域を多角形で示したシェープファイル形式データである。

航空撮影画像および斜面崩壊領域定義データの出典は以下の通りである。

- 航空撮影画像
  - 平成 30 年 7 月豪雨 正射画像 竹原三原地区(広島県竹原市・三原市など)(2018 年 7 月 10, 11, 12 日撮影)
  - 平成 30 年 7 月豪雨 正射画像 広島坂町地区(広島県広島市・坂町など)(2018 年 7 月 9, 11 日撮影)
- 斜面崩壊領域定義データ
  - 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), 2019 年 6 月 27 日

本研究では、学習・推論プログラムをオープンソースの深層学習ライブラリである pytorch を用いて構築しており、COCO データセットにより事前学習したモデルを使用している。また、使用した PC のス

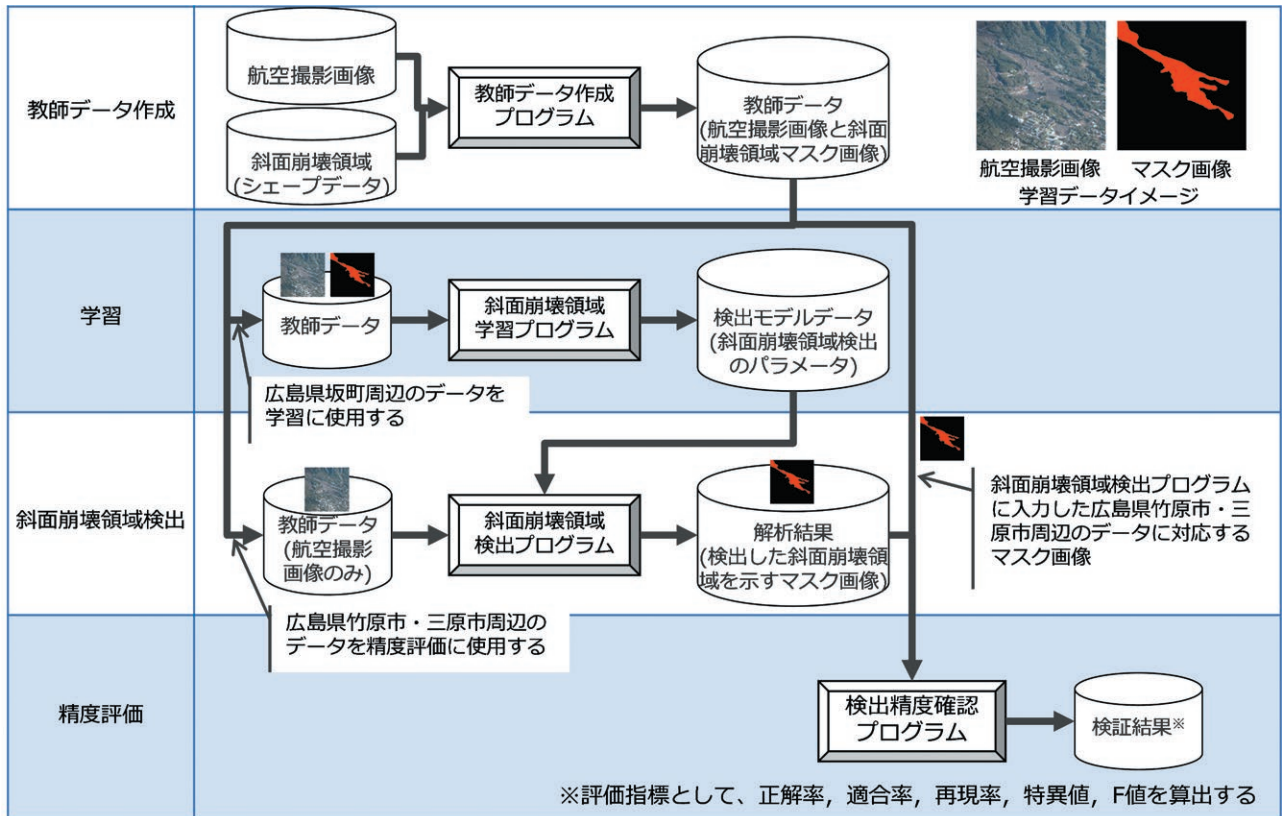


図1 学習データ作成から検証までのフロー

Fig. 1 A flow chart of each process (data creation, learning, detection, and precision evaluation).

ペックは以下の通りである。

- CPU : Intel® Core™ i9-9900KF CPU
- RAM : 64.0 GB
- GPU : NVIDIA GeForce RTX 2080Ti

#### 4. 学習・検証方法

##### 4.1 学習・検証フロー

Mask R-CNNは教師あり学習に分類される手法であり、教師データを与え学習プロセスを実行することにより、検出モデルを構築する。検出時は、学習済みの検出モデルに新たな航空撮影画像を入力すると、斜面崩壊領域を示すマスク画像を生成する。

教師あり学習では、教師データを訓練データと検証データに分け学習し構築したモデルの汎化性能の検証を行う。また精度評価には学習に使用しなかったデータを用いる。本研究では坂町地区のデータを学習に用い、75%を訓練データとし、残りの25%のデータで検証を行った。精度評価には竹原三原地区のデータを用いた。教師データ作成から検証までのフローを図1に示す。

##### 4.2 評価指標

精度検証の評価指標として、表1に示す5つの指標を算出した。後述の通り、精度検証では主に精度(F値)を用いた。なお評価指標の算出は画素単位の正解/不正解を基に行った。

表1 検出精度評価指標  
Table 1 Metrics.

指標	説明
正解率	正しく判定できた画素の割合
適合率	斜面崩壊領域と判定した画素のうち、判定が正しかった画素の割合
再現率	斜面崩壊領域の画素のうち、正しく斜面崩壊領域と判定された画素の割合
特異度	斜面崩壊領域ではない画素のうち、正しく斜面崩壊領域ではないと判定した画素の割合
精度(F値)	適合率と再現率の調和平均

## 5. 適用可能性の検証

### 5.1 教師データ作成

教師データは航空撮影画像と航空撮影画像内の斜面崩壊領域を示すマスク画像の組から成る。本研究では、使用する PC のメモリ環境を鑑み、教師データのサイズは 500×375 画素（航空撮影画像を 5×5 に分割した画像と同じサイズ）とした。マスク画像は斜面崩壊領域定義データと航空撮影画像の位置情報から作成した。図 2 に教師データのサンプルを示す。マスク画像内の赤色の領域が斜面崩壊領域を示す。

深層学習のモデルは膨大な数のパラメータから成るため、学習に大量のデータを必要とする。一方でこれらのデータは、収集の都合や教師データ作成のコストの問題から十分な量の確保が困難であることが多く、しばしば十分なデータの確保が問題となる。この問題に対応するために data augmentation 技術が用いられる。data augmentation では、収集したデータに平行移動や回転などの加工を人為的に施すことでデータ数を水増しする技術である。本研究でも既往研究（叶井ほか，2020）を参考に data augmentation として画像の回転（90°，180°，270°）を用い、データ数を 4 倍に水増しした。




図 2 教師データサンプル  
(左:航空撮影画像, 右:マスク画像)

Fig. 2 Samples of training data.  
(left: aerial images, right: mask images)

最後に教師データの選別を行った。今回学習への悪影響を及ぼす可能性がある教師データとして、下記 2 種のデータを教師データから削除した。

- 地上が映っていない領域を含むデータ  
航空撮影画像には、オルソ画像生成処理の都合や雲による遮蔽などの理由から、地上の画像を含まない部分が存在する。また斜面崩壊領域定義データは、今回使用する航空撮影画像のみから定義したのではないため、地上の画像を含まない部分にも斜面崩壊領域マスクが生成される可能性がある。このような地上が映っていない部分を斜面崩壊領域とする教師データは学習に悪影響を及ぼすため、事前に削除した。
- 斜面崩壊領域が占める割合が非常に小さい/写っていないデータ

斜面崩壊領域は、航空撮影画像の一部の限られた領域である。そのため必然的に教師データの中には非斜面崩壊領域の情報が多くなり、教師データに含まれる斜面崩壊領域とそれ以外の領域のバランスが非常に悪くなる可能性がある。偏りが非常に大きい教師データからの学習はモデルの汎用性を損ねる可能性があるため、斜面崩壊領域がデータ内に占める割合が低いデータを教師データから削除した。

図 3 に教師データから外したデータの例を示す。




図 3 教師データから外したデータの例  
Fig. 3 Samples of invalid training data.

### 5.2 学習と閾値の決定

前節の方法により作成・選別した教師データを用いて斜面崩壊領域検出のためのモデルを学習した。図 4 に学習結果を示す。

訓練用データ (training data) で算出した誤差を training loss, 検証用データ (validation data) で算出した誤差を validation loss と呼ぶ。両者の収束をもって学習の完了とし、validation loss が最小となる学習結果を採用した。図から validation loss は

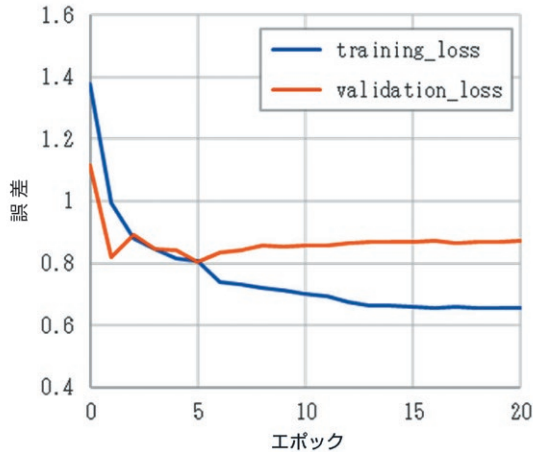


図4 学習結果  
Fig. 4 Learning result.




図5 閾値検討結果  
Fig. 5 Threshold study result.

5 エポックで最小 (0.81) となり、その後 15 エポック 辺りで 0.87 近辺に収束していることが分かる。また training loss (学習用データにおける誤差) も 18 エポック 辺りで 0.66 近辺に収束しているため、学習を 止め 5 エポックの学習結果を採用することとした。

Mask R-CNN の領域抽出タスクは、入力画像の各画素が対象である確率を出力する。本件では斜面崩壊領域であるか否かの 2 択であるため、斜面崩壊領域である確率に対して閾値処理を行うことで斜面崩壊領域検出の調整が可能となる。そこでこの閾値を 0.1 刻みで段階的に変更し精度 (F 値) が最も高くなる閾値を探索した。図 5 に閾値検討の結果を示す。閾値 0.7 の時、精度 (F 値) が 0.66 と最大となったため、閾値として 0.7 を採用した。

### 5.3 精度検証

精度検証には、教師データの近隣領域のデータを用いた。精度評価に際し、教師データ作成と同様に一定以上の割合で斜面崩壊領域を含む画像に限った場合 (斜面崩壊領域周辺のみ) と全領域を対象とした場合とに分けて検証した。また評価指標には、4.2 節で述べた指標を用いた。表 2 に検証結果を示す。

斜面崩壊領域周辺の場合、適合率、再現率はそれぞれ 0.670, 0.659 であり、高い精度は実現できていない。しかし正解率は 0.971 と非常に高く、精度向上の課題は残るものの、Mask R-CNN の斜面崩壊領域検出への適用が可能である。

一方で全領域の場合、斜面崩壊領域周辺の場合に比べ適合率が 0.67 から 0.272 と大幅に低下して

表 2 検証結果  
Table 2 Accuracy of detection result.

	斜面崩壊領域 周辺のみ	全領域
正解率	0.971	0.987
適合率	0.670	0.272
再現率	0.659	0.533
特異度	0.985	0.990
精度 (F 値)	0.664	0.361

いる。これは斜面崩壊領域周辺以外での誤検出が非常に多いことを示している。原因としては斜面崩壊領域周辺には見られない特徴を持つ領域があり、それらを学習できていないため誤検出が生じていると考えられる。誤検出の多さは実用に供する際に問題となる可能性が高く、対処が必要である。

図 6, 図 7, 図 8 に斜面崩壊領域検出結果例を示す。これらの検出結果から、検出漏れおよび誤検出箇所に以下の特徴があることが分かった。

- 検出漏れの傾向が見られる箇所の特徴
  - ✓ 比較的土の色が濃い
  - ✓ 影が差している
  - ✓ 地面が露わになっていない
  - ✓ 高架橋の下を土石流が潜り抜けている
- 誤検出の傾向が見られる箇所の特徴
  - ✓ 森林に隣接し地面が露わになっている
  - ✓ 森林を横切る道路や河川
  - ✓ 茶系色の屋根 (主に家屋)

したがって、これらの検出漏れ・誤検出の原因として、教師データに斜面崩壊領域、非斜面崩壊領域ともに十分なバリエーションが含まれていなかったことが考えられる。

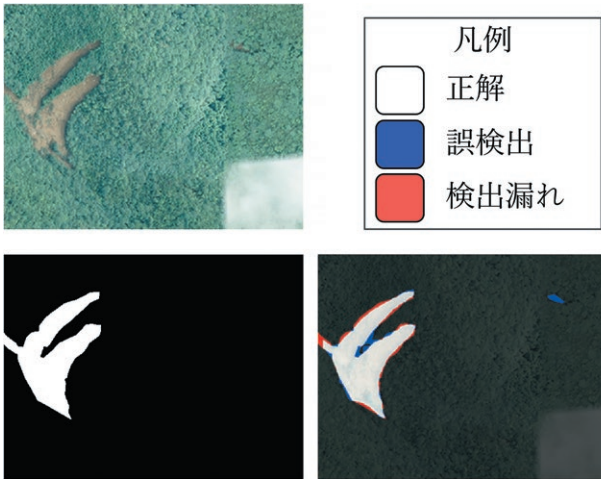


図 6 斜面崩壊領域検出結果例  
(良好な検出結果の例)

**Fig. 6** Slope failure detection results (useful samples).  
Upper row: Aerial photograph image,  
Lower left: Correct image,  
Lower right: Detection result,  
White: Correct answer, Blue: False positive,  
Red: Omitted detection.




図 7 斜面崩壊領域検出結果例

(誤検出・検出漏れの多い例) 凡例は図 6 と同じ  
**Fig. 7** Slope failure detection results (not useful samples).  
Figure legends are the same as in **Fig. 6**.  
Upper row: Aerial photograph image,  
Lower left: Correct image,  
Lower right: Detection result,  
White: Correct answer, Blue: False positive,  
Red: Omitted detection.




図8 斜面崩壊領域検出結果例(斜面崩壊領域をほとんど含まない領域の例)  
 (A) 斜面崩壊が少ない森林域での誤検出の例 (B) 森林域での正解に混在した誤検出の例 (C) 茶色い屋根の住宅や地面が露わになっている箇所が誤検出された例 (D) 大きな建物や住宅密集地での誤検出の例. 凡例は図6と同じ

Fig. 8 Slope failure detection results of areas that did not have slope failures.

(A) Example of false positives in a forested area with little slope failure (B) Example of false positives mixed with positives in a forested area (C) Example of false positives in a brown-roofed house or exposed ground (D) Example of false positives in a large building or dense residential area. Figure legends are the same as in Fig. 6.




図9 重み付き損失計算を用いた斜面崩壊領域検出結果例(斜面崩壊領域をほとんど含まない領域の例)  
 (A) 斜面崩壊が少ない森林域での誤検出の例 (B) 森林域での正解に混在した誤検出の例 (C) 茶色い屋根の住宅や地面が露わになっている箇所が誤検出された例 (D) 大きな建物や住宅密集地での誤検出の例. 凡例は図6と同じ

Fig. 9 Slope failure detection results using weighted loss for areas that did not include slope failure areas.

(A) Example of false positives in a forested area with little slope failure (B) Example of false positives mixed with positives in a forested area (C) Example of false positives in a brown-roofed house or exposed ground (D) Example of false positives in a large building or dense residential area. Figure legends are the same as in Fig. 6.

**表 3** 教師データ取捨選別の有無による精度比較  
**Table 3** Precision comparisons of learning with and without training data selection.

	取捨選別あり	取捨選別なし
正解率	0.987	0.991
適合率	0.272	0.402
再現率	0.533	0.439
特異度	0.990	0.995
精度(F 値)	0.361	0.420

**表 4** 追加学習の精度検証  
**Table 4** Precision comparisons of additional learning and learning without training data selection.

	取捨選別なし	追加学習
正解率	0.991	0.991
適合率	0.402	0.414
再現率	0.439	0.457
特異度	0.995	0.996
精度(F 値)	0.420	0.434

### 5.4 精度向上方法の検討

前節の通り、試行の結果 Mask R-CNN の斜面崩壊領域検出への適用可能性が確認できた。一方で、全領域を対象とした場合に精度が低下することも分かった。そのため、実用に供するためには全領域を対象とした場合の精度向上の必要がある。

前節の検証の結果、検出漏れや誤検出の一部の箇所にはいくつかの共通の特徴を確認できたため、教師データに斜面崩壊領域のバリエーションが不足していることが精度低下の一因と考えられる。そこで精度向上方法として、教師データを追加し学習する下記 3 手法を検証した。

1. 教師データ取捨選別を廃止  
 教師データの取捨選別を止めることで、教師データのバリエーション不足を補った。
2. 追加学習  
 学習が不足していると思われるデータのみを選別し、追加で学習した。
3. 重み付き損失計算  
 1. の手法で懸念される教師データの不均衡による悪影響を抑えることを狙った手法。学習時の損失計算に教師データ全体に含まれる斜面崩壊領域の面積割合に応じた重みを導入した。

#### 5.4.1 教師データの取捨選別を廃止

前節の試行では、画像内に含まれる斜面崩壊領域の面積に応じて、学習に用いる教師データの取捨選別を行った。これは教師データに含まれる斜面崩壊領域とそれ以外の領域の面積の不均衡がもたらす学習への悪影響を避ける目的であった。しかし検証の結果、斜面崩壊領域、非斜面崩壊領域共に教師データに含まれるバリエーションが不足しているために精度が低下している可能性があることが分かった。そこで取捨選別前の教師データ全体を用いて学習

し、前節の結果と比較した。ただし地上が写っていない領域を含む教師データの削除は、不適切な教師データの削除を目的としたものであるため、引き続き実施した。結果の比較は全領域のデータで行った。表 3 に結果を示す。

正解率は 0.987 から 0.991、精度 (F 値) は 0.361 から 0.420 にそれぞれ向上した。一方で再現率は 0.533 から 0.439 に低下した。これらは検出漏れが増えたもののそれ以上に誤検出が低下し、全体的に精度が向上したことを示している。したがって、教師データの取捨選別は行わない方が良いが、精度 (F 値) が十分であるとは言えないため、その方法に課題が残る。

#### 5.4.2 追加学習

次に前節で学習したモデル (前モデルと呼ぶ) の追加学習による精度向上について検証した。具体的には、前節で学習したモデルが誤検出もしくは検出漏れの傾向にあった特徴を持つデータのみを教師データに追加し、前モデルの追加学習を行った。表 4 に追加学習の結果を示す。

精度 (F 値) は教師データの取捨選別なしに比べ、全体的に追加学習の精度の方が僅かに高い。ただし教師データの取捨選別ありと比較すると、再現率は 0.1 近く低下している。これらのことより教師データの取捨選別あり同様、追加学習は精度向上に寄与するが検出漏れが増加する傾向にあることが分かった。またその効果は追加学習の方が高いことが分かった。追加学習の方が高い精度となった理由として、必要な教師データのみ追加できたため、データの不均衡の悪影響を抑えることが出来たことが考えられる。しかし本手法は追加する教師データの選定が必要であるため、選定作業の負荷が懸念される。



表 5 重み付き損失計算の精度検証  
Table 5 Precision comparisons of weighted loss and additional learning.

	追加学習	重み付き損失
正解率	0.991	0.991
適合率	0.414	0.398
再現率	0.457	0.501
特異度	0.996	0.995
精度(F 値)	0.434	0.443

### 5.4.3 重み付き損失計算

前述の通り，5.1 節の教師データの取捨選別では学習に効果的な教師データを捨てている可能性があり，また追加学習は精度向上に有効であるが追加する教師データの選別の負荷が懸念される．そこで教師データの選別の負荷を抑えつつデータ不均衡の悪影響を抑える方法として，重み付き損失計算を検討した．具体的には，学習時に計算する損失を学習用データに含まれる斜面崩壊領域と非斜面崩壊領域の面積に応じた重みを付けて計算した(式 1)．表 5 に重み付き損失計算の検証結果を示す．

$$\begin{aligned}
 \text{損失} &= w_1 \times \text{斜面崩壊領域の損失} \\
 &+ w_2 \times \text{非斜面崩壊領域の損失} \\
 w_1 &: \frac{\text{非斜面崩壊領域の面積}}{\text{全領域の面積}} \\
 w_2 &: \frac{\text{斜面崩壊領域の面積}}{\text{全領域の面積}}
 \end{aligned} \tag{1}$$

教師学習の取捨選別なし，追加学習と較べ全体的な精度(F 値)は向上した．追加学習に較べ適合率は落ちているが再現率が向上しており，検出漏れを抑える方向に調整されたことが伺える．また教師データの取捨選別ありの結果と比較しても，全体的な精度(F 値)は向上している．他の検討手法同様，再現率は教師データの取捨選別ありと較べ低下しているが，検討した精度向上手法の中で一番低下率を抑えることが出来た．これらのことより，重み付き損失計算は精度向上の観点で一番有効である．

図 9 に重み付き損失計算を用いた場合の斜面崩壊領域をほとんど含まない領域の検出結果を示す．図 8 と比較すると誤検出が減っていることが確認できる．しかし特に下段の領域では改善はしているものの未だ誤検出が多く対処が必要である．

最後に斜面崩壊領域周辺のみを対象とした場合に

表 6 教師データ取捨選別ありと重み付き損失計算の精度比較(斜面崩壊領域周辺のみ)

Table 6 Precision comparisons of learning data selection and weighted loss (slope failure areas and their surroundings).

	取捨選別あり	重み付き損失
正解率	0.971	0.973
適合率	0.670	0.720
再現率	0.659	0.636
特異度	0.985	0.989
精度(F 値)	0.664	0.675

ついて，教師データの取捨選別ありと重み付き損失の精度を比較する．表 6 に両者の精度を示す．

全領域を対象とした場合同様，全体的な精度(F 値)は向上するが再現率のみやや低下する結果となった．したがって，斜面崩壊領域周辺とそれ以外の領域で重み付き損失計算による精度向上の傾向に大きな違いはなく，重み付き損失計算による精度向上策は全領域に対して適用可能と考える．

## 6. まとめ

航空撮影画像からの斜面崩壊領域検出への Mask R-CNN の適用可能性を確認した．一方で非斜面崩壊領域では誤検出が増加し，精度が低下することが分かった．非斜面崩壊領域も含めた精度向上策として，過度に教師データの選別を行わず重み付き損失計算を導入することが有効であることを確認した．

今後の課題として，教師データの増加による精度向上の検討や地域，災害の種別による精度の相違の検証が考えられる．また災害対応として本手法を活用する方法や必要機能についての検討も必要である．

## 参考文献

- 1) 大八木規夫・内山庄一郎・井口隆(2008)：「2004 年新潟県中越地震による斜面変動分布図」の解説，防災科学技術研究所研究資料第 317 号．
- 2) 広島大学平成 30 年 7 月豪雨災害調査団(地理学グループ)(2018)：平成 30 年 7 月豪雨による広島県の斜面崩壊分布図(第一報)，[http://www.ajg.or.jp/disaster/files/201807\\_report001.pdf](http://www.ajg.or.jp/disaster/files/201807_report001.pdf) (2022 年 7 月 27 日閲覧)

- 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(第二報:最終報告), [http://www.ajg.or.jp/disaster/files/201807\\_report008.pdf](http://www.ajg.or.jp/disaster/files/201807_report008.pdf) (2022 年 7 月 27 日閲覧)
- 4) Sakai, Y., Takemoto, S., Hori, K. Nishimura, M., Ikematsu, H., Yano, T., and Yokota, H. (2018): Automatic detection of early gastric cancer in endoscopic images using a transferring convolutional neural network. 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Honolulu, HI, USA, 4138-4141, doi: 10.1109/EMBC.2018.8513274.
- 5) He, K., Gkioxari, G., Dollár, P., and Girshick, R. (2017): Mask R-CNN, IEEE Conference on Computer Vision and Pattern Recognition, 2980-2998.
- 6) 河村圭・中村優志・若月強・佐村俊和(2018) : 深層学習を用いた空中写真からの土砂移動範囲自動検出に関する研究, 土木学会論文集 F3(土木情報学), Vol.74, No.2, I\_132-I\_143.
- 7) 叶井和樹・山根達郎・石黒聡士・全邦釘(2020) : Semantic Segmentation を用いた斜面崩壊領域の自動検出, AI・データサイエンス論文集 1 (J1), 421-428.
- 8) 叶井和樹・久保栞・山根達郎・全邦釘(2021) : Mask R-CNN による航空撮影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), 223-231.
- (2023 年 4 月 13 日原稿受付,  
2023 年 5 月 8 日改稿受付,  
2023 年 6 月 14 日原稿受理,  
2024 年 4 月 30 日公開)

## 要 旨

航空撮影画像からの斜面崩壊領域検出に対する画像認識技術の適用可能性の検証を行った。画像認識手法は、画像内の検出対象領域を画素単位で抽出する image segmentation 技術の 1 つである Mask R-CNN を採用した。また学習・検証には平成 30 年 7 月豪雨直後の広島地域の航空撮影画像(オルソ画像)および専門家による斜面崩壊領域検出結果を用いた。斜面崩壊領域は撮影画像中の限られた領域であるため必然的に画像に含まれる斜面崩壊領域の面積はそれ以外の領域に比べ非常に少なくなる。精度向上策として、この教師データの不均衡への対処法についても検証を行った。検証の結果、教師データの不均衡に応じた重みを学習時の損失計算に導入することの効果を確認でき、最終的な斜面崩壊領域検出の精度は F 値 0.68 であった。

今後の課題は、データ増加も含めた検出精度の向上や地域や災害種別が異なる場合の精度確認・対応である。また災害対応として本手法を活用する方法や必要機能についての検討も必要である。

キーワード : 斜面崩壊, Image segmentation, Mask R-CNN (Region-Based Convolutional Neural Network)