

# 可視画像と DEM を利用した斜面崩壊地の自動判別手法の検討

長岡技術科学大学院 ○ 金川哲也, 高田竜司  
東京電力ホールディングス株式会社 岡滋晃  
長岡技術科学大学 高橋一義

## 1. はじめに

電力網をはじめとする社会インフラは日本の平野から山間部まで広く網羅し, 我々の生活を陰から支える重要な役割を果たしている. ゆえに災害などによってインフラが寸断された場合は早期に修繕を行い, 生活基盤としての役割を復旧することが求められる. しかしながら, 山間部にある一部のインフラ設備はアクセスそのものが容易ではない. また, 被災直後の安全調査を目視に頼っていることから被災状況の把握に時間を要しており, これが早期復旧の妨げとなっている.

これに対する解決策の一例として空撮写真や衛星画像などを利用した深層学習による被災箇所の検知がある. 菊池ら<sup>1)</sup>は微地形強調図を用いた斜面崩壊地の検出を行っている. これらの研究を参考に, 著者らは可視画像を使用した深層学習を行い, 新潟県中越地震によって山間部で発生した斜面崩壊地の検出を試みた<sup>2)</sup>.

本稿では可視画像に地形情報 (DEM, DSM) を加えた深層学習を行い, 斜面崩壊地の自動判別結果にみられた変化を報告する.

## 2. 使用データ

発災前の可視画像にはオルソ処理済 pansharpen QuickBird 画像 (2003 年 9 月 5 日撮影, 画素サイズ 50cm), 発災後には空中写真のデジタルスキャン画像 (2004 年 10 月 24 日撮影, 345 シーン) から作成したオルソモザイク画像 (画素サイズ 50cm) を使用する. また, 発災前の地形情報には 1975 年の空中写真から作成された DEM データ (画素サイズ 2m)<sup>3)</sup>を, 発災後の地形情報には先述したオルソモザイク作成時に生成した DSM (画素サイズ 2m) を使用する.

## 3. 手法

### 3.1 斜面崩壊地判別

本稿では学習済みニューラルネットワークを再学習することで学習データが少なくとも深層学習が可能な転移学習を行う. 学習済みニューラルネットワークに

は GoogLeNet を使用する. GoogLeNet の入力層は 3 層 (3 変量) となっている. 使用データに含まれる変量は発災前後の RGB (3 変量×2) と発災前後の地形情報 (1 変量×2) の計 8 変量である. このうち先行研究と同じ 3 種 (発災前の緑, 発災後の緑, 発災後の赤) に発災前後の地形情報を加えた 5 変量から後述する 4 ケースの組み合わせを作成し, 入力データとする. 入力データの大きさ (パッチサイズ) は 25m (50pixel) 四方とする.

これらパッチの内部 70%以上を崩壊地が占めるものに崩壊地, 非崩壊地が占めるものに非崩壊地を割り当てる. ラベルを割り当てたパッチは 2 割を評価用パッチとして分離し, 残りの 8 割によって転移学習を実施する. 学習終了後, 転移学習済みネットワークを用いて評価用パッチの分類を行う.

### 3.2 ネットワーク評価手法

転移学習を行ったネットワークの判別性能を評価用パッチの分類結果から評価する. 使用する指標は以下の式(1)で表される正解率, および式(2)で表される再現率とする.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

ここで, Accuracy は正解率, Recall は再現率, TP は真陽性, FN は真陰性, TN は偽陰性, FP は偽陽性を示す.

### 3.3 入力データ

発災前後の可視画像および地形情報の内, 表-1 に示す 4 ケースの組み合わせを入力データとする. 表中の 2 文字からなる記号は各変量の時期とデータ種別を示す. B と A は発災前と後, r, g, b はそれぞれ可視画像の赤, 緑, 青バンド, d は地形情報を表す DEM あるいは DSM を意味している.

表-1 入力データ

ケース	変量		
1	Bg	Ag	Ar
2	Bd	Ad	Ag
3	Bg	Ag	Bd
4	Bg	Ag	Ad

ケース1は先行研究と同じ変量の組み合わせであり、地形情報を加えた組み合わせとの比較ケースである。ケース2はケース1の組み合わせのうち最も発災前後の変化が大きいと考えられるAg（発災後可視画像の緑）と発災前後の地形情報の組み合わせである。ケース3, 4は発災前後の可視画像（緑）と発災前、発災後の地形情報をそれぞれ組み合わせたものである。

#### 4. 結果と考察

表-1に示す4ケースの入力データでGoogLeNetを転移学習させ、評価データを分類した結果から再現率、正解率を算出した（表-2）。

表-2 ケースごとの判別結果

ケース	再現率 (%)		正解率 (%)
	崩壊地	非崩壊地	
1	72.1	93.8	82.9
2	89.2	70.0	79.6
3	70.8	87.9	79.4
4	79.6	80.8	80.2

それぞれをケース1と比較すると、全てのケースで非崩壊地の再現率が減少しており、それにもなつて正解率も低下している。崩壊地の再現率についてはケース2, 4で向上がみられたものの、発災前の地形情報を利用したケース3は低下している。ケース2とケース4を比較すると、発災前後の地形情報を利用したケース2の崩壊地再現率がより高い値となっている。

以上から、崩壊地の再現率向上には発災後の地形情報を利用することが有効であり、発災前の地形情報と合わせることでより高い効果を得ることができると推測される。一方で、地形情報の利用は非崩壊地の再現率を減少させ、ネットワーク全体の正解率を低下させるものと考えられる。

また、各ケースの誤判別されたパッチを比較した所、

ケース2にてそれらがまとまって減少している領域が複数確認された。これらは崩壊地のラベルが割り振られていながら、斜面そのものがずれ落ちて草付きのある山肌がそのまま残った、あるいは崩壊地へ向けて周囲の木々が崩れ落ちたことによってパッチ内の多くを森林や草草が占めているとみられる場所であった。

このことから、ケース2は地形情報を2種利用し、可視画像（緑）がもたらす情報量を減らしたことによって先行研究では検出できなかった崩壊地を捉えることが可能になったものと考えられる。

#### 5. まとめ

本稿では先行研究で行われていた斜面崩壊地自動判別を行う際の学習データに地形情報を加え、検出結果にいかなる影響がもたらされるかを検証した。

地形情報を取り入れた3ケースの組み合わせのパッチで転移学習を行い、崩壊地を判別した所、被災後の地形情報を利用した2つのケースで崩壊地の再現率が向上した。また、この2ケースのうち発災前の地形情報を合わせて利用したものは再現率がより高くなった。一方で非崩壊地の再現率が減少しており、正解率は低下した。

今後は入力可能な情報量を増やして深層学習がより多くの特徴を学習できるようにするとともに、次元圧縮等によって特徴量を縮約し、崩壊地の検出性能が向上するかを調査する。

また、本研究の結果から崩壊地の検出には地形情報が、非崩壊地の検出には可視画像（緑）が影響する傾向にあることが予測される。今回は使用しなかった他の変量についても指標に影響を及ぼすのか検証したい。

#### 参考文献

- 1) 菊池輝幸ら：深層学習による崩壊、非崩壊地の自動判別手法の開発、日本地すべり学会誌 Vol.56, 第5巻 pp.255-263, 2019.
- 2) 高田竜司ら：深層学習と発災前後の可視画像情報を用いた斜面崩壊地抽出の検討、日本リモートセンシング学会 第70回学術講演会, 2020.
- 3) 小長井一男：活褶曲地帯における地震被害データアーカイブスの構築と社会基盤施設の防災対策への活用法の提案、文部科学省科学技術振興調整費, 2007.