

# 機械学習を用いた斜面の崩壊予測手法における学習データの影響分析

長岡技術科学大学 非会員 ○ 五十嵐大輝  
長岡技術科学大学 非会員 小林倫  
長岡技術科学大学 正会員 大塚悟  
長岡技術科学大学 正会員 福元豊

## 1. はじめに

近年は豪雨による自然災害が多発している。2001年に土砂災害防止法が制定され、ハード対策に加えてソフト対策が推進されるが、近年ではコンピュータの急激な発展に伴い、AIによる斜面災害の分析が活発に取り組まれている。筆者らは区間の異なる移動平均を用いた地形情報や地上開度、地下開度を用いた機械学習による斜面崩壊の危険度予測評価(Step1)を行うとともに、崩壊危険度評価結果を用いた画像認識により、崩壊危険箇所をブロック単位で抽出する(Step2)、2段階の予測手法を検討してきた。予測精度の向上には機械学習における学習データの量及び質が重要であるが、本研究では、予測評価に適切なデータセットを作成することを目的とし、学習及びテストに使用する崩壊データ数の割合が予測精度へ与える影響を調査し、画像認識により抽出される崩壊危険ブロックの解析評価について比較検討を行う。

## 2. 検討対象地域

対象地域は、平成23年7月に発生した新潟・福島豪雨において災害調査が行われた新潟県魚沼地方を流れる魚野川流域(図1)である。1mメッシュで流域内全てを扱うとデータ数が膨大となるため、図中の矩形部(5,000×5,000m)を今回の検討範囲とした。この範囲内には474の崩壊箇所があり、崩壊面積は最小で6.7m<sup>2</sup>、最大で2,329m<sup>2</sup>である。

## 3. Step1 機械学習による危険度評価

### 3.1 解析概要

災害時の斜面の崩壊・非崩壊を目的変数とし、説明変数は複数のスケールの地形情報を含んだ30項目(1mメッシュ、移動平均5m及び移動平均10mでの標高、傾斜角、曲率、断面曲率、平面曲率、起伏量、累積流量、地上開度、地下開度及び尾根谷度)とした。

分類手法はバギング木であり、学習データの25%を用いてホールドアウト検証を行い、過学習を起さないことを確認した。解析範囲の総データ数25,000,000個のうち、崩壊データは94,560個、非崩壊データは24,905,440個である。表1に示す通り、学習及びテストに使用する崩壊データ数の割合を変化させた4種の解析事例により比較を行う。

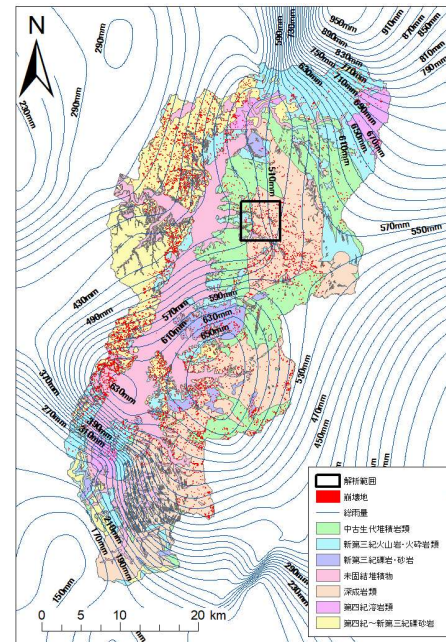


図1 対象地域の概要

表1 学習データ規模の影響検討(解析事例)

	学習		テスト	
	崩壊データ	非崩壊データ	崩壊データ	非崩壊データ
case1	18,912 (20%)	18,912	75,648 (80%)	24,886,528
case2	37,824 (40%)	37,824	56,736 (60%)	24,867,616
case3	56,736 (60%)	56,736	37,824 (40%)	24,848,704
case4	75,648 (80%)	75,648	18,912 (20%)	24,829,792

### 3.2 解析結果

予測結果の評価には、表2の混同行列により算出した精度(崩壊と予測した中で実際に崩壊だった割合)と真陽性率(実際の崩壊を崩壊と正しく予測できた割合)を用いた。各caseの解析結果を図2に示す。学習に使用する崩壊データの割合が増加するに従って、予測精度及び真陽性率は向上することが示された。図3は各caseの崩壊危険度評価と実際の崩壊形

表 2 混同行列

		予測	
		崩壊	非崩壊
実際	崩壊	TP	FN
	非崩壊	FP	TN

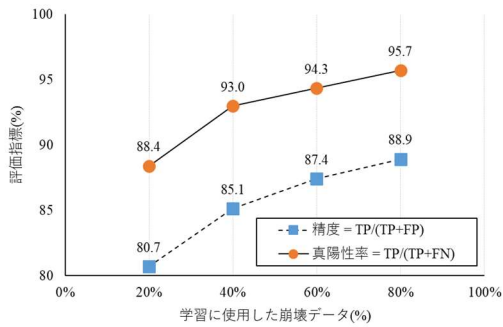


図 2 学習データによる崩壊危険度の精度 (Step1)




図 3 崩壊危険度評価と実際の崩壊形状

状を示しており、赤色は危険度が高く、青色は危険度が低いことを示している。崩壊データの学習使用数が多いほど、危険度評価での曖昧な予測をした黄色の箇所が減少し、より強弱をつけた判定を行うことが明らかになった。

#### 4. Step2 画像認識による崩壊危険ブロックの抽出

##### 4.1 解析概要

ここでは Step1 で得られた解析結果を使用し、崩壊危険ブロックの抽出を行う。解析には既存の画像を学習し、新たな画像を作成する pix2pix を用いた。入力画像は case ごとの斜面崩壊危険度評価、正解画像は実際の崩壊データである。1 枚当たりのサイズは  $256 \times 256$  ピクセルとし、崩壊を 1%以上含む 46 枚を学習データ、残りの 354 枚をテストデータとした。

##### 4.2 解析結果

Step2 の解析結果を図 4 に示す。学習に使用した崩壊データ数が多いほど、精度は高くなり、真陽性率は case3 を除き、精度と同様な傾向となった。各 case の入力画像、画像認識による生成画像及び正解画像を図 5 に示す。case1 は危険度評価が曖昧な箇所が多く、全く関係ない場所を崩壊として認識している。case2

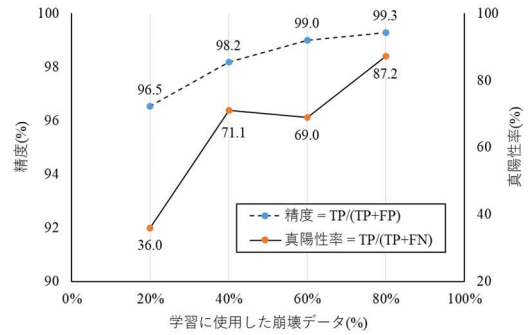


図 4 学習データによる崩壊危険度の精度 (Step2)

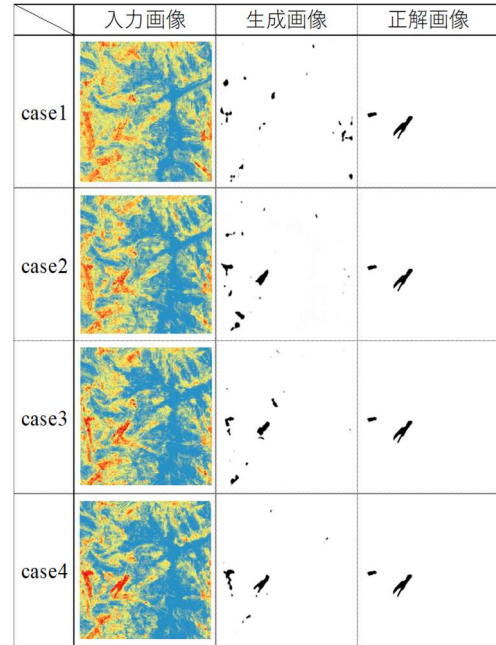


図 5 抽出された崩壊危険ブロックの形状

と case3 を比較すると、case2 の方は実際の崩壊よりも多くの箇所を崩壊危険ブロックとして抽出している。そのため、case3 よりも真陽性率は高くなるが、精度は低くなると考えられる。case4 では実際の崩壊形状をある程度補足しており、ブロックとして抽出可能であることが確認された。

#### 5. まとめ

本研究では、崩壊データ数の変化による予測性能の検討を行った。どの段階においても、学習に使用する崩壊データ数が多いほど精度・真陽性率が高くなり、正解の形状に近い崩壊危険ブロックを抽出できることが判明した。より安全に配慮した評価を行うためには、実際の崩壊箇所だけに絞って予測するよりも、崩壊箇所周辺を含む危険度の高いエリアを抽出の方が望ましいと考える。今後は、説明変数に用いる特徴量や入力画像サイズの最適化といった学習データの「質」に着目した検討を行っていく。