

# 事例解析による斜面属性と AI 斜面広域危険度の分析

環境防災研究室

S223220 杉谷 倫亮

指導教員 大塚 悟

## 1. はじめに

近年、わが国では特に集中豪雨による土砂災害が増加している。1999 年の広島豪雨を契機に、2001 年には土砂災害防止法が制定され、ハード対策だけでなく、ソフト対策の重要性が強調された。しかし、依然として集中豪雨による斜面崩壊が発生しており、2021 年 7 月の静岡県熱海市を含む豪雨では多くの被害が発生した。

近年ではコンピュータ技術の進展により、AI による斜面崩壊の予測が進んでいる。例えば、古川ら<sup>1)</sup>は仙台市と熊本市における地形特徴と地すべり、崩壊発生点の関係を共分散構造分析と機械学習によって評価した。しかし、そのほとんどが独立したメッシュを用いており、周囲の地形特徴を考慮できていない。実際の崩壊のうち、大規模崩壊はマクロな地形の影響を受けるのに対して、小規模な崩壊はミクロな地形の影響を受ける。そのため、メッシュ単位で崩壊現象との関連を調査する従来の方法は斜面の崩壊特性を反映しない。このような問題に対して會川<sup>2)</sup>は、移動平均による広域情報を入力したモデルを用いて比較検討を行った。

## 2. 研究目的

本研究は地形的特徴の異なる各地域に対して、広

域情報を入力した機械学習による予測を実施し、その結果を入力とする画像認識を行うことで、崩壊ブロックを抽出することを目的とする。また同時に、各地域での崩壊予測に最適の地形データを明らかにする。

機械学習による予測では、平成 23 年 7 月の豪雨を対象にして、DEM のサイズおよび移動平均値の大きさを変化させた場合の崩壊予測を行い、使用する地形データによる解析制度の差異を考察する。

画像認識による予測は、画像変換アルゴリズム pix2pix を用いて、崩壊地密度の高い箇所を崩壊ブロックとして抽出することをねらいとしている。

## 3. 機械学習を用いた崩壊予測

ここでは、地形的特徴の異なる 4 地域について機械学習を行い、各地域でのモデルの分類性能の可視化と評価を行った。一例として、Area-D で算出された分類性能の指標を表 1 に、危険度評価値を可視化したものを図 1, 2 に示す。すべてのエリアで、移動平均値を用いた場合により高い精度が得られた。また、1mDEM の場合、指標のみ(10 項目)や、指標と移動平均値を組み合わせる学習項目数を増やす(30 項目)場合よりも、移動平均 10m の地形量のみ(10 項目)を用いた場合に高い精度が得られる傾向がある。

表 1 分類性能の指標(Area-D)

	1mDEM				5mDEM		10mDEM
	指標	指標+移動平均	移動平均5m	移動平均10m	指標	移動平均10m	指標
正解率	78.5	89.8	86.7	91.6	70.3	72.2	65.6
精度	81.8	90.7	88.1	92.1	76.1	77.4	73.3
真陽性率	97.3	99.3	98.9	99.5	95.0	95.7	94.7
真陰性率	78.4	89.8	86.6	91.5	70.1	72.0	65.4
偽陽性率	21.6	10.2	13.4	8.5	29.9	28.0	34.6
偽陰性率	2.7	0.7	1.1	0.5	5.0	4.3	5.3

5mDEM 地形量を用いた場合でも、移動平均値を用いた場合に優位性がみられた。危険度評価図では、学習項目を増やした場合に危険度評価値が 0.5~0.7 のあいまいな領域が減少したため、よりはっきりとしたモデルになると考えられる。しかし、5mDEM や 10mDEM を使用した際に、予測性能の大幅な低下がみられるため、細かな地形の起伏を考慮することが必要であると考えられる。

#### 4. 画像 AI 解析を用いた崩壊ブロックの抽出

機械学習の結果をもとに、各エリアで最も精度が高くなったケースに対し、同様の条件で pix2pix を用いた画像認識を行った。一例として、Area-B の危険箇所抽出結果を図 3 に示す。機械学習で崩壊と予測された箇所が密集するところでは崩壊ブロックが抽出された。また性能指標に関して、すべてのケ

ースで正解率および精度が向上することが確認された。対して真陽性率はすべてのケースで低下した。画像認識によって正解率・精度が向上するのは、機械学習で崩壊と判定された箇所が集中するところが画像認識で崩壊ブロックとして抽出されやすく、対照的に小規模の崩壊は見逃されてしまうため、崩壊地密度の高いところでの崩壊判定、崩壊地密度が低いところでの非崩壊判定が増えることが原因と考えられる。実際に 500 m<sup>2</sup> 以上の大規模な崩壊箇所の多い Area-B では、正解率・精度が大幅に向上し、真陽性率が大幅に低下した。



図 3 画像認識で抽出された危険箇所




図 1 危険度評価図(1mDEM の 10 項目)




図 2 危険度評価図(1mDEM の 30 項目)

#### まとめ

本研究では、特徴の異なる地域に対して機械学習および画像認識を行った。機械学習では、1mDEM の地形量を使用した際により性能が得られた。また DEM サイズに関わらず、移動平均値を用いるとより性能が向上することが確認された。画像認識では、機械学習で崩壊と予測された箇所が密集するところで崩壊ブロックが抽出された。しかし、そうでない箇所は非崩壊と判定されるため、すべてのケースで精度が向上し、真陽性率が低下した。

#### 参考文献

- 1) 古川ら, 共分散構造分析と機械学習に基づく 地すべりと土砂崩壊地点の地形的特徴の評価, 地震工学論文集, 37, 2018
- 2) 會川健朗, 機械学習と画像認識技術を組み合わせた斜面の AI 広域危険度評価に関する研究, 長岡技術科学大学大学院修士論文, 2023