

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

環境防災研究室 會川健朗

指導教員 大塚 悟

1. はじめに

2001 年に土砂災害防止法が制定されて以来、斜面災害のソフト対策が推進され、斜面災害の危険度評価が多数行われてきた。従来の斜面危険度評価は、数値化 II 類や重回帰分析等の多変量分析が主流であったが、AI を用いた豪雨や地震による斜面崩壊に関する研究が行われてきている。しかし、多くは斜面の属性を DEM の要素毎に評価して、斜面の崩壊および非崩壊のイベントとの相関を解析している。斜面の崩壊規模を考えると、大規模の崩壊はマクロスケールの地形の影響を受けるのに対して、崩壊規模の小さい崩壊はミクロスケールの地形の影響を受ける。したがって、従来の方法は斜面の崩壊特性を反映しない問題がある。そこで本研究では、既往の研究の知見を参考として、広域の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 2 段階の予測を試みた。1 段階目の機械学習によるポイントワイズな危険度評価では、H23 年 7 月豪雨を対象として広域な情報を入力した既往のモデルの精度向上を目的に、地形情報の 5m 及び 10m 移動平均を用いたほか、赤色立体図で用いられる地上開度、地下開度、尾根谷度を追加で入力し、バギング木によるモデルを作成した。加えて発展的な検討として、他地域への適用性についても検討した。2 段階目の pix2pix を用いた崩壊ブロックの抽出では、まず、pix2pix における崩壊ブロックの抽出に最適なモデル、学習画像のサイズ及び種類について検討し、崩壊ブロックの生成を試みる。

2. 対象範囲と使用データ

今回用いたデータは、平成 23 年 7 月に発生し

た新潟・福島豪雨において崩壊の有無の調査が行われた範囲である。この地域は、豪雨が発生する以前に地形調査が行われており斜面崩壊の予測に適したデータである。データ数が膨大であるため、図 1 の範囲から対象地域を絞った、羽根川流域、佐梨川流域に跨る矩形のエリア (5,000m×5,000m) を対象地域とした。これを「Area-A」と呼ぶ。また、他地域への適用性を検討する領域として、標高、総雨量、地質の分布状況、崩壊形態が異なる芋川流域内の矩形のエリア、宇田沢川流域、三国川流域に跨る矩形のエリアを設定した。いずれも 5,000m×5,000m の矩形である。これを「Area-B」、「Area-C」と呼ぶ。矩形部の対象地域では範囲が狭く降雨量に変化がみられないため、地形情報を用いた解析を実施する。

3. STEP1：機械学習

3.1 データベースの構築及び予測手法

Step1 では、応答変数を災害時の崩壊・非崩壊の事象とし、予測子変数を 1m DEM から移動平均 5m 及び 10m の情報をもつ DEM を作成した。ArcGIS を用いて、(1) 標高、(2) 傾斜角、(3) 曲率、(4) 断面曲率、(5) 平面曲率、(6) 起伏量、(7) 累積流量、(8) 地上開度、(9) 地下開度、(10) 尾根谷度のデータを 1m、移動平均 5m、移動平均 10m ごとに作成した。ArcGIS で数値化したデータについて MATLAB を用いて予測を行った。本稿では Area-A における地理情報データベースを基にバギング木による予測を行う。応答変数は崩壊及び非崩壊の事象とした。Area-A において崩壊データ(セル数)は 94,560 個、非崩壊データ(セル数)は 24,905,440 個抽出された。また、予測子変数は上述した地形的特徴量とし、広域情報を入力しない 1m メッシュ単体のモデ

ル (Case1), 広域情報を入力した既往のモデル (Case2), 精度向上を目的に既往のモデルに地上開度, 地下開度, 尾根谷度を追加で入力したモデル (Case3) の 3 種について検討を行った。

3.2 予測結果

本稿では, 機械学習において精度の検証に用いられることの多い混同行列を用いた。混同行列の値から, 正解率, 精度, 真陽性率, 偽陰性率, 真陰性率, 偽陽性率の 6 つの指標によりモデルを評価する。表 1 に作成したモデルにおける分類性能の指標を示す。精度が最も高いモデルは Case3 の 87.4%, 次いで Case2 の 78.3%, Case1 は 59.6% となり, 異なるスケールの特徴量を使用したモデルの優位性がみられた。Case1 と, Case2 では後者の精度が高い結果となった。これより, 広域情報を入力することで機械学習の予測精度が向上することが確認できた。Case2 と Case3 では後者の精度が高い結果となった。図 1 に崩壊面積毎の真陽性率の関係を示す。広域情報を入力しない 1m メッシュ単体のモデルでは崩壊面積が小さい場合, 真陽性率は 60%程度となっている。一方で, 既往のモデルに地上開度, 地下開度, 尾根谷度を追加で入力したモデルでは真陽性率は 90%程度となっており, 性能が向上していることがわかる。これは地上開度, 地下開度, 尾根谷度を追加することで, 広域情報を入力した既往のモデルには入力されていない地形の凹凸, 開き具合が数値として入力され, 面積の小さい崩壊から, 大きい崩壊までを分類できるようになったことを示している。すべての数値において, 今回の値が良好な結果であることから, 斜面崩壊の AI を用いた予測において, 既往研究の広域的な情報の入力に加え, 地上開度, 地下開度, 尾根谷度といった地形の凹凸, 開き具合を入力することが有効であることが確認された。

3.3 他地域への適用に向けた検討

Area-A について作成した分類モデルが, 標高, 総雨量, 地質の分布状況, 崩壊形態が異なる地

域に適用が可能かを検証する。バギング木には最大分割数のパラメータがあり, この値が大きくなるとモデルの柔軟性がなくなり他地域への適用が困難になると考えられる。そこで, 3.2 で作成した Case3 について, 最大分割数を変化させ他地域への適用を試みる。図 2 に各エリアにおける最大分割数と真陽性率の関係を示す。Area-A においては最大分割数が大きいほど真陽性率が高くなるがやがて一定の精度に落ちつく傾向がみられた。一方, Area-B, Area-C では最大分割数を少なくすることで, 崩壊を判定できるようになるが, それでも真陽性率は 50%前後とよくはない。これは, 入力データの分布が異なる地域同士では, 崩壊予測に影響を及ぼす地形量が異なるため, 適用性が低くなることが明らかとなった。このことから斜面崩壊の特性は地域性が大きく, 学習データも同地域のデータの必要性が確認された。

表 1 Area-A における分類性能の指標

指標	Case1	Case2	Case3
正解率	56.0%	75.9%	86.2%
真陽性率	65.0%	87.2%	95.8%
真陰性率	56.0%	75.9%	86.2%
偽陰性率	35.0%	12.8%	4.2%
偽陽性率	44.0%	24.1%	13.8%
精度	59.6%	78.3%	87.4%




図 1 崩壊面積と真陽性率の関係

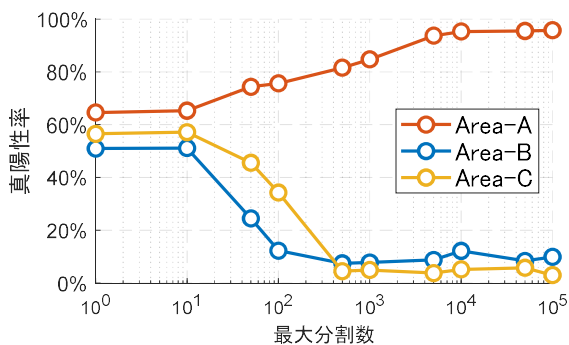


図2 各エリアに適用した場合の真陽性率

4. STEP2 : 画像認識

4.1 画像認識手法

本研究では個人の裁量に依存するラベル付けを行う必要がなく、短時間で学習が可能である pix2pix を採用した。正解画像は STEP1 で用いた崩壊データを二値画像化して使用した。入力画像は、本研究で提案する手法の危険度評価値を画像化した画像(グレースケール)、RGB 値に異なる情報を付随した画像を作成した。RGB にはそれぞれ、R : 危険度評価値、G : 傾斜角、B : 尾根谷度を与えた。傾斜角と尾根谷度は赤色立体図に用いられる地形量である。また、既往研究では検討されていなかった画像サイズについても検討を行う。入力画像が 2 種類、画像サイズを 64×64, 128×128, 256×256 の 3 サイズとし、計 6 ケースの生成モデルを作成した。尚、テストデータは学習に使用していない 30 ペアとし、生成結果を比較するために一律で 256×256 とした。

4.2 画像認識結果

本稿では、画像認識の定量的な精度は生成結果で崩壊と判断したピクセルの内どの程度正しく崩壊ピクセルだけを崩壊として生成しているかを評価した。STEP2 の機械学習による危険度評価の画像を用いた画像認識についての結果を表 2, 図 3 に示す。どの入力画像の場合でも、精度が 90%後半で崩壊範囲の形は表現されており範囲の抽出ができています。画像サイズ

の違いによる比較では、サイズによって生成される崩壊個所の複雑さが異なる傾向がみられる。これは全画素数と崩壊個所の画素数の比率が関係していると考えられる。画像サイズが小さい場合は崩壊個所の比率は高くなり、崩壊個所も分割して学習することになる。複雑な形状をしている崩壊個所も、画像サイズが小さくなることで単純かつ大きな形状となる。一方で画像サイズが大きい場合は崩壊個所の比率は低くなり、崩壊個所は小さく複雑な形状で学習することになる。入力画像の種類による比較では、画像サイズが大きい場合、RGB 値に異なる情報を付随した画像では、崩壊していない部分を誤って小さな崩壊と判定してしまうケースが少なくなる。しかし画像サイズが小さい場合、崩壊個所が生成されなくなっている。以上の検討から危険度評価値をグレースケールとした画像を細かく分割して学習させたモデルが最適であることが明らかとなった。図 4 に機械学習の危険度評価図と画像認識の生成結果を重ねた図を示す。機械学習の危険度評価図に画像認識の生成結果を用いることで、崩壊が起こりうる個所が点在していたものを、崩壊ブロックとして抽出することができ、その視認性が向上することが確認できた。

5. おわりに

STEP1 では、スケールを変えた地形情報を用いる手法の提案について検討した。6 つの指標で評価した結果多様なスケールの地形量の有効性と必要性、優位性が確認された。赤色立体図に用いられる地形量を追加することでさらなる精度の向上が確認された。STEP2 では pix2pix を用いて崩壊個所の抽出を試みた。その結果、危険度評価値をグレースケールとした画像を細かく分割して学習させたモデルが最適であることが明らかとなった。





図3 テストデータの生成画像*

(上段：グレースケール画像，下段：RGB 値に異なる情報を付随した画像)

*入力画像，生成画像，正解画像は階調を反転して表示している



機械学習で得られる危険度評価値 生成した崩壊ブロックを重ねた図

図4 機械学習の危険度評価図と画像認識の生成結果を重ねた図

表2 テストデータによる定量的評価(赤：性能が最も高い，青：性能が最も低い)

	危険度評価値を画像化した画像			RGB 値に異なる情報を付随した画像		
	①	②	③	④	⑤	⑥
学習画像サイズ (pixel)	256×256	128×128	64×64	256×256	128×128	64×64
正解率	99.2%	99.2%	98.6%	99.3%	99.3%	99.0%
真陽性率	79.1%	75.5%	81.9%	75.2%	72.6%	55.9%
真陰性率	99.3%	99.3%	98.7%	99.5%	99.5%	99.3%
偽陰性率	20.9%	24.5%	18.1%	24.8%	27.4%	44.1%
偽陽性率	0.7%	0.7%	1.3%	0.5%	0.5%	0.7%
精度	99.0%	98.8%	98.3%	92.7%	95.9%	95.1%