

12. 深層学習による細密 DEM ごとの崩壊リスク評価

Deep learning for the assessment of slope failure risk by detailed digital elevation models


佐藤丈晴（岡山理科大学）

1. はじめに


豪雨に伴う崩壊に対して、適切な対策を行うには、崩壊リスクが高い場所を予測する必要がある。航空測量データを用いた地形解析図によって定量的に地形を把握できるようになった。この地形解析図を AI による画像認識技術を用いて危険度評価が盛んにおこなわれている。一方崩壊リスク評価において、勾配や斜面の凹凸等の地形量と崩壊の関係に着目した研究は古くから実施されている（塚本（1973）、沖村（1983）等）が、この視点からの AI を用いた研究は、ほとんど実施されていない。本研究では、豪雨時に初生的に発生した崩壊に着目し AI を用いた DEM（メッシュとも記す）単位の崩壊リスク評価を行った。

2. リスク評価に用いた 3 次元地形モデル

本研究では、航空レーザ測量データから算出できる 1mDEM を用いて検討した。対象地域は、平成 21 年中国・九州北部豪雨によって、甚大な被害を受けた山口県防府市とした。豪雨前後に航空レーザ測量が行われているため、オルソ画像の他、差分による崩壊地の特定が可能となる。本研究では、この初生的な崩壊箇所に着目して解析データを作成した。オルソ画像を



図－1 研究対象位置図



図－2 崩壊地(教師)データの作成

用いた崩壊箇所の設定を行った事例(図－2の崩壊地_元データ)もあるが、目的が異なるデータであるため採用しない。オルソ画像に DEM の差分を加えた検討から、初生的な崩壊地を特定した(図－2の崩壊地_本研究)。また、初生的な崩壊か二次的な崩壊かの判断が難しい場所は、崩壊地から削除した。


崩壊地周辺の微地形は、当該メッシュ周辺の DEM の 3 次元座標値から、当該メッシュとの比高差（比高差と記す）、勾配、ラプラシアンを算出した。崩壊地の平均面積が 50m²を下回ることから、当該メッシュ周辺の 7×7 メッシュの DEM を用いて 3 次元地形モデル（図－3）を構築し、崩壊地に対する素因とした。その算定式は次のとおりである。

$$HD_{ij} = Z_{ij} - Z \quad \dots\dots\dots (1)$$

HD_{ij} : 比高差

Z_{ij} : 周辺メッシュの標高値

Z : 当該メッシュの標高値



図－3 比高差の算定方法例

勾配とラプラシアン の計算方法については、様々な数式が提案されているが、本研究では下記の数式を用いた。当該メッシュと、その南北方向と東西方向に隣接したメッシュの標高値から地形量を算出した。

$$Slope = \frac{360}{2\pi} \cdot \arctan \left[\sqrt{\left(\frac{Z_E - Z_W}{2\Delta x} \right)^2 + \left(\frac{Z_N - Z_S}{2\Delta y} \right)^2} \right] \quad \dots (2)$$

$$lap = \left(\frac{Z_E - 2Z + Z_W}{\Delta x^2} \right) + \left(\frac{Z_N - 2Z + Z_S}{\Delta y^2} \right) \dots (3)$$

Slope : 勾配

lap : ラプラシアン

Z : 当該メッシュの標高値

Z_N : 北側メッシュの標高値

Z_S : 南側メッシュの標高値

Z_E : 東側メッシュの標高値

Z_W : 西側メッシュの標高値

$\Delta x, \Delta y$: *x*軸方向, *y*軸方向のメッシュ間隔

この計算を研究対象地域全域で計算し、図-3に示した3次元地形モデルでは、当該メッシュの説明変数として7×7=49メッシュすべての勾配とラプラシアンを用いる。

以上より、本研究で当該メッシュにおける説明変数の数は、式(1)～(3)で算定した比高差、勾配、ラプラシアンの3要因であり、周辺7メッシュ分の147個(49×3)となる(図-4)。

3. 採用したニューラルネットワークモデル

本検討では、147個の説明変数の数値を用いて、




図-4 解析データの入出力関係

当該メッシュの崩壊リスクを評価する階層型ニューラルネットワークを採用した。




図-5 パーセプトロン

最も基本となるのは、前層のすべての出力値 x_i の和を受け取り、出力値 y を返すパーセプトロンである(図-5)。このとき、前層のニューロンとの結合部には重み w_i があり、正しい評価値を出力するために、 w_i を適切な値に調整することを学習という。ディープニューラルネットワークに対してこの学習を行うことを深層学習と呼ぶ。本研究では、適切な深層学習を行うことで、適切な高崩壊リスク箇所の抽出を可能とする予測システムの構築を目指す。

入力値 x_i と出力値 y の関係は活性化関数と呼ばれる次の関数

$$y = f \left(\sum w_i x_i + b \right) \quad \dots (4)$$

b : バイアス

で表される。本研究で用いた活性化関数 f は、説明変数であるラプラシアン及び比高差が0を標準値とし、かつ負の数値に意味のある要因であるため、双曲線正接関数 $y = \tanh(x)$ を採用した。

検討の結果、10 溪流の平均的な最適モデルは、4 層階層型、第1中間層 441 個(入力層の3倍)、第2中間層 147 個(入力層の1倍)のDNN(図-6)であり、予測精度は88.22%である(図-7)。予測できなかった12%弱の細密DEMは、崩壊地との地形類似性が高い場所であり、この細密DEMを高崩壊リスク箇所と定義する。




図-6 本地域で最適な予測モデル

4. 解析結果

最適モデルで高崩壊リスク箇所と評価された場所を図-8に示した。主に0次谷の凹地部




図-7 予測精度の比較

分に集中分布している。平成 21 年中国・九州北部豪雨で崩壊した場所をほぼ含んでおり、同様の降雨を経験すれば崩壊の可能性が高い場所といえる。高崩壊リスク箇所は、細密 DEM ごとに解析しているが、隣接 DEM ではほとんど地形が変化しないため、塊を作って分布している。高崩壊リスク箇所の塊の最も標高の高い場所は、尾根部の線緩線付近に達している。線緩線を含んだ尾根部付近から下流側の谷沿いは崩壊危険性が高いと評価している。0 次谷内においても微細な凸状地形の部分は高崩壊リスク箇所から除外されており、凹部のリスクを高く評価している。塚本他 (1973) は、0 次谷と山崩れの関係进行调查しており、山崩れ発生可能地点は、0 次谷の谷線上にあるとしており、解析結果は、この傾向に合致する。この微細な地形の凹凸は、沖村 (1983) でも使用されているラプラシアン値の傾向に類似しており、3 次元地形モデルのラプラシアン値の分布が微細な地形状況を適切に評価していると考えられる。





図-8 危険度評価の一例 (No2 神里川流域)



図－8 解析結果（No2 神里川流域）

5. 溪流危険度評価への適用


高崩壊リスク箇所を用いた0次谷ごとの危険度評価について図－8に例示する。図－8中の0次谷の勾配は、ほぼ15度を上回り、豪雨時に高崩壊リスク箇所が発生した崩壊土砂は、表流水及び地下水とともに0次谷から土砂流出すると想定できる。危険度評価の基本的な考え方は、流域内に分布する高崩壊リスク箇所の面積が広い（細密DEMの数が多い）ほど、土砂流出の危険度が高いと評価する。

図－8に示した55箇所の0次谷に対して、高崩壊リスク箇所（細密DEMの個数）と流域面積を整理した結果を図－9に示した。

本研究では、高崩壊リスク箇所を示した細密DEMの数について、200箇所と500箇所の二つの閾値を設けて3ランクに分類した（図－9）。図－8中に地図上の流域に対して危険度ランクごとに着色した。細密DEMごとの高崩壊リスク箇所は、対象地域、評価単位を問うことなく危険度評価を容易に行うことができる。

謝辞

本稿執筆に当たり、解析に使用した航空レーザ測量データを貸与いただいた国土地理院にこの紙面を借りて深く感謝申し上げます。また、



図－9 危険度ランク分類

本研究は、日本学術振興会 科学研究費助成事業「点検技術者の視点に基づいた土砂災害発生リスク評価手法の開発」により行いました。記して謝意を表します。

参考文献

- 塚本良則（1973）：侵食谷の発達様式に関する研究（I）－豪雨型山崩れと谷の成長との関係についての一つの考え方－，新砂防，Vol.87，pp.4-13.
- 沖村孝（1983）：地形要因からみた山腹崩壊発生危険度評価の一手法，新砂防，Vol.35，No.3，pp.1-8.