

VI-247

ニューラルネットワークを用いた土石流危険渓流における  
土石流または山腹崩壊のリアルタイム発生予測に関する研究

山口大学工学部 正会員 大木戸孝也  
中電技術コンサルタント 正会員 荒木 義則  
山口大学工学部 正会員 古川 浩平

1. はじめに

近年、国民の生活の場が扇状地や傾斜面上など土砂災害の危険のある場所にまで広がり、土砂災害の人的被害が顕著となってきた。そこで本研究では、過去に幾度も土石流災害に見舞われている広島県西北部（山県郡加計町及びその周辺）の風化花崗岩からなる渓流を対象として、パターン認識に優れるニューラルネットワークを用い、素因である地形要因と誘因となる降雨要因を用いて、渓流毎に土石流や山腹崩壊の発生をリアルタイムで判断する評価システムを構築した。また、ニューラルネットワークモデル（以下、NNモデル）の汎化能力を向上させるための学習データの取り扱い及び学習方法について検討した。

2. 使用要因

本研究を進めるに当たり、使用した要因を以下に示す。

地形要因：水系模様、流域平均勾配、最急溪床勾配、主溪流長、流域面積、溪流幅、溪床堆積厚さ、流域長、流域幅、流域形状比、谷深比、0次谷の数、流域最大傾斜、源頭部面積、溪床危険度評価、溪床堆積厚評価、降雨集中度評価

降雨要因：時間雨量、実効雨量（半減期24hr）、降雨重心

3. ニューラルネットワークモデル

本研究では入力層、中間層、出力層の3層からなる階層型ネットワークモデルを用い、学習アルゴリズムはバックプロパゲーション法（以下、BP法）とし、学習回数は1万回とした。

4. リアルタイム発生予測

一般的に、土石流発生渓流は非発生渓流に比べて少ない場合が多い。本研究で取り扱ったデータに関しても、発生データ数が非発生データ数の1/20程度と少なかった。そこで、NNモデルの構築に際しては、表-1に示すように、発生データ数や学習回数を変化させた5つの検討ケースを設定し、各検討ケースを用いてリアルタイム発生予測を行った。その結果、一連の降雨において正しい判断が行われた渓流数を図-1に示す。発生渓流については発生推定時刻に正しく認識できたもの、非発生渓流については一連の降雨において非発生を正しく認識できたものを正解とした。

図-1より、集中学習を行った検討ケース2～5は、基本モデルである検討ケース1に比べて、発生・非発生とも精度の向上が見られた。中でも発生渓流に対して最も正解率が高いのは、検討ケース4の発生データを4倍にした場合であった。

キーワード：土石流、山腹崩壊、ニューラルネットワーク、発生予測、リアルタイム

連絡先：山口県宇部市常盤台2557 Tel 0836-35-9111 Fax0836-35-9429

表-1 NNモデルの精度向上のための検討ケース

| 検討ケース | 内 容                                 | 最大学習回数 | 発生       | 非発生 | 発生・非発生合計 |
|-------|-------------------------------------|--------|----------|-----|----------|
| 基本モデル | 1 全渓流に全ての降雨要因を用いる。発生・非発生データの数は変化なし。 | 10,000 | 36       | 736 | 772      |
| 集中学習  | 2 全渓流に全ての降雨要因を用いる。発生データを2倍にする。      | 10,000 | 36×2=72  | 736 | 808      |
|       | 3 全渓流に全ての降雨要因を用いる。発生データを3倍にする。      | 10,000 | 36×3=108 | 736 | 844      |
|       | 4 全渓流に全ての降雨要因を用いる。発生データを4倍にする。      | 10,000 | 36×4=144 | 736 | 880      |
|       | 5 全渓流に全ての降雨要因を用いる。最大学習回数を3万回にする。    | 30,000 | 36       | 736 | 772      |





図-1 全データに対するリアルタイム発生予測の結果



(a) 検討ケース 1 (b) 検討ケース 4  
図-2 時間雨量と実効雨量(半減期24hr)を変化させた感度解析の一例(エリア4-3における発生溪流No.20)

## 5. NNモデルの降雨要因に関する感度解析

土石流または山腹崩壊の発生した代表的な溪流として、エリア4-3発生溪流No.20の地形要因を用いて、降雨要因を変化させた感度解析を行う。降雨要因は3要因あるため、降雨重心を発生推定時刻の値に固定し、時間雨量と実効雨量(半減期24hr)を変化させた場合の発生確信度の変化を図-2に示す。図中の(a)は検討ケース1、(b)は検討ケース4における感度解析結果をそれぞれ表している。

図-2より、(a)の検討ケース1に関しては、同じ実効雨量でも時間雨量の大きいものの方が発生確信度が高くなっており、一般的な特徴と一致している。しかしながら、(b)の検討ケース4に関しては、同じ実効雨量でも時間雨量が大きくなるにつれ発生確信度が上昇し、時間雨量40~60mmを越えると下降しており、一般的な常識と異なっている。

これは図-3に示す降雨特性より、学習を行った発生降雨データは、時間雨量38~61mm、実効雨量(半減期24hr)174~250mmの範囲に分布していることに起因していると思われる。したがって、この確信度の下降現象は、学習した発生降雨データを越える降雨データに対して現れており、NNモデルの判断に関しては外挿領域にあることがわかる。これは既往の発生データに対する正解率を向上させるには有効であるが、逆に、将来、異なった降雨データが生じた場合には、危険側の予測をする可能性がある。一般に、ニューラルネットワークの学習アルゴリズムであるB.P法では、外挿は困難とされており、NNモデルの利用においては、本研究で示したようにモデルの特性を明らかにした上で、内挿の範囲内で適用する必要がある。また、今後、土石流または山腹崩壊の発生データ増えれば、その都度、ニューラルネットワークの学習機能を用いて追加学習を行えば、より精度の高いモデル構築が可能になると考えられる。




図-3 時間雨量と実効雨量(半減期24hr)の学習データと未学習データの分布領域

## 6. 結論

- 1) ニューラルネットワークを用いた土石流または山腹崩壊の発生予測は、発生・非発生データ共に高い正解率が得られた。
- 2) 土石流または山腹崩壊の発生は、一般に発生データに比べて非発生データが多くなる傾向がある。このような場合には、発生データを集中的に学習することにより、発生データに対する正解率を更に向上させることが可能となる。本研究で試みた中では、発生データを4倍にして学習させた場合が最も高いリアルタイム予測結果が得られた。
- 3) 降雨要因による感度解析から、土石流または山腹崩壊の発生データを集中学習させたNNモデルは、基本モデルに比べて発生降雨データの分布範囲をよりの確に捕らえて事が確認された。

## 参考文献

- 1) 建設省土木研究所砂防部砂防研究室：土石流の警戒・避難基準雨量の設定に関する研究，土木研究所資料，pp.9-11，1985.3