

# ニューラルネットワークを用いた豪雨時の急傾斜地におけるがけ崩れ発生・非発生の判別手法について

山口大学工学部 ○菊池 英明 山口県土木建築部砂防課 石村 和寿  
 山口大学工学部 古川 浩平 山口県土木建築部砂防課 飛渡 一敏  
 山口市 河村 浩恵 千葉市 大木戸孝也

## 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、全国的にも急傾斜地崩壊危険箇所数の多い山口県の軟岩及び強風化岩からなる斜面を対象にして、パターン認識に優れたニューラルネットワークを用い、素因である斜面要因と誘因となる降雨要因を基に、斜面毎にがけ崩れ発生・非発生を判別するシステムの構築を行う。

また、最適な降雨要因の抽出、及びニューラルネットワークモデル（以下、NNモデル）の判別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

本研究を進めるにあたり、使用した斜面要因を以下に示す。なお、これらの各要因は全て、平成8年度危険箇所調査報告書に記載されている調査項目である。

- ・地形要因：延長、傾斜度、高さ、斜面形状、横断形状、遷急線
- ・土質・地質要因：地表状況、表土厚さ、岩盤亀裂、斜面不連続面、断層破碎帯、風化状況
- ・環境要因：植生の種類、伐採根の状況、崩壊履歴、斜面状況、湧水の有無、対策工の有無

降雨要因の組み合わせとしては、次の3つのケースを考えた。

Case 1：時間雨量，累積雨量，降雨継続時間

Case 2：N時間雨量 (N=4～10)

Case 3：N時間雨量 (N=4～10)  
累積雨量，降雨継続時間

ここで、N時間雨量とは、図-1の降雨要因抽出点の例に示すように、数時間分の時間雨量をそれぞれ要因として用いることを言い、本研究ではその幅を4～10時間としている。また、各ケースにおける降雨要因の抽出点は、非発生降雨の場合、一連の降雨における最大時間雨量を記録した時刻とした。発生降雨の場合は、Case 1はがけ崩れ発生時刻以前において最大時間雨量を記録した時刻とし、Case 2及びCase 3においては、報告されている発生時刻としている。

## 3. NN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とし、学習回数は1万回とした。また、使用したNNモデルは、中間層の層数やニューロン数を様々に変化させることにより、教師データに対して最適と思われるNNモデルとした。図-2にニューラルネットワークモデルの一例を示す。




図-1 降雨要因の抽出点の例




図-2 ニューラルネットワークモデル

表-1 各CaseにおけるNNモデルの収束状況と正解率

| 地盤状況 |         |          | 軟岩        |           |           | 強風化岩      |           |           |       |
|------|---------|----------|-----------|-----------|-----------|-----------|-----------|-----------|-------|
| Case |         |          | Case 1    | Case 2    | Case 3    | Case 1    | Case 2    | Case 3    |       |
| 中間層  | 層数      | 1層       | 1層        | 2層        | 3層        | 2層        | 3層        | 3層        |       |
|      | ニューロン数  | 9        | 8         | 8         | 9         | 8         | 8         | 8         |       |
| 学習方法 | 方法      | 3倍       | 5倍        | 3倍        | 2倍        | 4倍        | 2倍        | 2倍        |       |
| 入力時間 | 雨量の幅    |          | 6         | 6         |           | 8         | 8         |           |       |
| 収束状況 | 学習回数    | 1,533    | 10,000    | 3,739     | 10,000    | 10,000    | 1,067     |           |       |
|      | 最小二乗誤差  | 0.000945 | 0.002323  | 0.000982  | 0.003266  | 0.012963  | 0.000987  |           |       |
| 正解率  | 教師データ   | 平成6年迄    | 発生        | 20/22     | 22/22     | 21/22     | 46/48     | 42/48     | 47/48 |
|      |         |          |           | 90.9      | 100.0     | 95.5      | 95.8      | 87.5      | 97.9  |
|      |         |          | 984/984   | 981/984   | 984/984   | 1098/1098 | 1095/1098 | 1097/1098 |       |
|      |         | 非発生      | 100.0     | 99.7      | 100.0     | 100.0     | 99.7      | 99.9      |       |
|      |         |          | 1004/1006 | 1003/1006 | 1005/1006 | 1144/1146 | 1137/1146 | 1144/1146 |       |
|      |         |          | 99.8      | 99.7      | 99.9      | 99.8      | 99.2      | 99.8      |       |
|      | テストデータ  | 平成7年     | 発生        | 1/3       | 3/3       | 1/3       | 2/4       | 3/4       | 2/4   |
|      |         |          |           | 33.3      | 100.0     | 33.3      | 50.0      | 75.0      | 50.0  |
|      |         |          | 359/375   | 353/375   | 374/375   | 156/176   | 171/176   | 175/176   |       |
|      |         | 非発生      | 95.7      | 94.1      | 99.7      | 88.6      | 97.2      | 99.4      |       |
|      |         |          | 360/378   | 356/378   | 375/378   | 158/180   | 174/180   | 177/180   |       |
|      |         |          | 95.2      | 94.2      | 99.2      | 87.8      | 96.7      | 98.3      |       |
| 平成9年 | 発生      | 2/2      | 1/2       | 2/2       | 1/2       | 2/2       | 2/2       |           |       |
|      |         | 100.0    | 50.0      | 100.0     | 50.0      | 100.0     | 100.0     |           |       |
|      | 136/190 | 190/190  | 190/190   | 157/179   | 178/179   | 179/179   |           |           |       |
| 非発生  | 71.6    | 100.0    | 100.0     | 87.7      | 99.4      | 100.0     |           |           |       |
|      | 138/192 | 191/192  | 192/192   | 158/181   | 180/181   | 181/181   |           |           |       |
|      |         | 71.9     | 99.5      | 100.0     | 87.3      | 99.4      | 100.0     |           |       |

#### 4. 発生予測

一般的に、土砂災害に関するデータは非発生データに比べ発生データが少ない場合が多い。本研究で取り扱ったデータに関しても、発生データ数と非発生データ数の格差が最大で40倍強となっている。

そこで、NNモデルの構築にあたって、1回の学習につき発生データのみn倍学習をさせる集中学習を行った。また、その際に全てのケースについてn=1~6としている。

表-1に地盤状況別に、各ケースにおいて最も良好な結果を示したNNモデルの収束状況と判別結果を示す。表-1より、各ケースにおいて、最適なNNモデルの構造には統一性がなく、地盤状況別、使用降雨要因別に最適なNNモデルが存在するものと思われる。また、集中学習における発生データの倍数(n)に関しては、強風化岩よりも発生データ数と非発生データ数の格差が大きい軟岩は多くの集中学習が必要であることから、発生・非発生の両データに関して良好な正解率を得るためには、両者の比率に一定の幅があるものと考えられる。本研究においては、発生データ数は全体の10%前後は必要であるという結果に至った。

教師データに対する正解率は、全てのケースにおいて非常に高く、良好な学習が行えたといえる。また、テストデータに関しては、いずれの地盤状況においても、降雨要因としてN時間雨量(N=4~10)のみを用いたCase 2の正解率が最も高く、軟岩では発生データに対しては80%、非発生データに対しては96%。強風化岩では発生データに対しては83%、非発生データに対しては98%と良好な結果を示した。これに対して、降雨要因として従来の研究でよく用いられる時間雨量、累積雨量、降雨継続時間を用いたCase 1の場合、Case 2よりも発生・非発生データともに判別結果が悪い。また、Case 2の降雨要因に累積雨量と降雨継続時間を加えたCase 3においては、発生データの正解率は低下しているものの、非発生データに関しては向上している。このことから、がけ崩れの発生予測においては、降雨要因としてN時間雨量が有効であり、他の降雨要因と組み合わせることにより判別能力の向上も十分に可能になると考えられる。

#### 5. 結論

- ①ニューラルネットワークを用いたがけ崩れの発生・非発生判別は、発生・非発生ともに高い正解率が得られたが、地盤状況による崩壊特性の違いから、中間層の層数やニューロン数を変化させ、最適なNNモデルの構築を図る必要があると考えられる。
- ②学習方法は、発生データをn倍(n=1~6)学習させることにより、発生・非発生データ数の格差を解消し、あわせて判別能力の向上を行うことが可能である。本研究では、発生データ数を全体の10%前後にいたるまで倍した場合に良好な結果を得られた。
- ③降雨要因として数時間分の時間雨量を要因とするN時間雨量を用いることにより、判別能力が向上した。