

ニューラルネットワークによる豪雨時のがけ崩れ発生・非発生 の判別手法に関する研究

山口大学大学院
八千代エンジニアリング（株）
山口大学工学部

学生員 ○瀬口武三郎
正会員 菊池英明
正会員 倉本和正

山口県砂防課
中電技術コンサルタント（株）
山口大学工学部

正会員 鉄賀博巳
正会員 荒木義則
正会員 古川浩平

1.はじめに

日本は温暖湿潤気候に属し降雨の大半が梅雨時期や台風の季節に集中する為、その時期には全国各地で土砂災害が発生し尊い人命や貴重な財産が失われている。しかも、がけ崩れの危険性のある急傾斜地崩壊危険箇所は年々増加していることが明らかになっている。そこで本研究では、非線形性を有する問題に適用性が高いニューラルネットワークを用いることにより、がけ崩れ発生・非発生判別システムを構築し判別システムの精度向上手法について検討する。

2. 使用データの概要

本研究では、山口県における急傾斜地崩壊危険箇所実態調査の斜面データから降雨の均一性を考慮して気象庁観測所半径 5km 以内の 852 個のデータを使用する。本研究で用いた斜面要因は、地形に関する 6 調査項目、地質・土質に関する 8 調査項目、環境要因に関する 9 調査項目、地震要因に関する 3 調査項目である。なお本研究では、これらの斜面要因に基づくデータを岩石区分ごとに用いる。分析に用いる降雨データは、1976 年～1997 年の各気象庁観測所アメダスデータより発生・非発生の降雨データを抽出する。降雨要因には降雨の特徴を表すために、時間雨量、累積雨量、降雨継続時間を使用する。

3. ニューラルネットワークモデルの概要

本研究では図-1 に示すように、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る。入力層は地形要因と降雨要因によって構成され、それぞれの要因は実数値で示されているデータを 0～1 の間に基準化して用い、カテゴリー区分されているデータはそのまま使用する。中間層は 1 層としニューロン数 7 個とした。また、出力層のニューロンはがけ崩れの発生・非発生の 2 個を設定している。学習アルゴリズムはバックプロパゲーション法を用い、学習の収束条件としては、最小二乗誤差 ≤ 0.0001 または最大 10,000 回の反復学習を行った。

4. 発生・非発生データの抽出方法

発生・非発生降雨データの抽出方法および降雨要因の抽出時刻は、様々な抽出方法が考えられる。本研究で得られた最良の発生・非発生降雨の組み合わせと降雨要因の抽出時刻を次に示す。

- ・発生降雨：災害報告書によりがけ崩れ発生の報告時刻が確定しているデータを全て使用し、発生時刻の降雨要因を抽出する。
- ・非発生降雨：各気象庁観測所の対象期間内における非発生降雨の中から、一連の降雨中の 1 時間最大時間雨量値が最大となる降雨を抽出する方法(時間雨量基準)と、時間雨量基準に加え一連の降雨の中で累積雨量が最大となる降雨を抽出する方法(時間雨量 + 累積雨量基準)を用いる。降雨要因の抽出時刻は 1 時間最大雨量発生時刻とする。

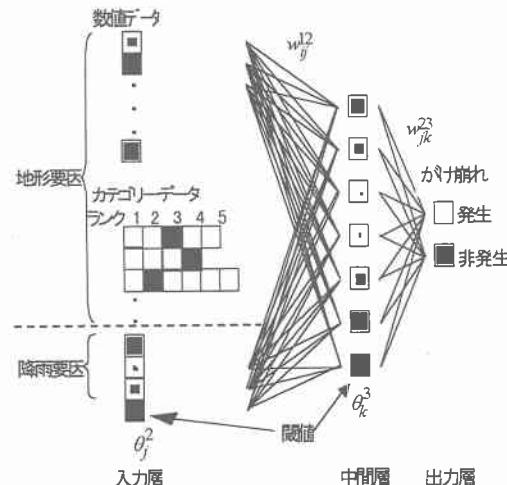


図-1 ニューラルネットワークモデル

5. 判別結果と評価

今回構築した最良ケースの学習結果と発生・非発生の判別結果を表-1に示す。最良ケースでの学習結果は、表-1に示すように時間雨量+累積雨量基準の深成岩類を除く全ケースで最小二乗誤差を満足して学習が終了し、全ての学習データに対して正解を与えていた。このことから非常に高い精度で学習が行われたことが分かる。テストデータに対する判別結果を見ると発生データでは固結堆積物を除き時間雨量基準により非発生データを抽出した方が一般的に高い判別結果が得られている。しかし、非発生データの判別率は若干ではあるが逆に劣る結果となっている。岩石区別に見ると、時間雨量基準のケースで未固結堆積物、火山性岩石で70%以上の良好な判別率が得られている。

表-1 最良ケースの学習結果および発生・非発生の判別結果

非発生降雨要因		時間雨量基準					時間雨量基準+累積雨量基準				
岩種名		未固結堆積物	固結堆積物	火山性岩石	深成岩類	変成岩類	未固結堆積物	固結堆積物	火山性岩石	深成岩類	変成岩類
収束状況	学習回数	253	196	259	459	361	187	398	324	10000	275
	最小二乗誤差	0.0001	0.0001	0.0001	0.0001	0.0001	0.000099	0.0001	0.005556	0.0001	
正判別率	学習データ	発生	24/ 24 100.0%	15/ 15 100.0%	29/ 29 100.0%	20/ 20 100.0%	7/ 7 100.0%	24/ 24 100.0%	15/ 15 100.0%	29/ 29 100.0%	19/ 20 95.0%
		非発生	68/ 68 100.0%	122/ 122 100.0%	159/ 159 100.0%	80/ 80 100.0%	46/ 46 100.0%	136/ 136 100.0%	244/ 244 100.0%	318/ 318 100.0%	160/ 160 100.0%
		全体	92/ 92 100.0%	137/ 137 100.0%	188/ 188 100.0%	100/ 100 100.0%	53/ 53 100.0%	160/ 160 100.0%	259/ 259 100.0%	347/ 347 100.0%	179/ 180 99.4%
	テストデータ	発生	8/ 11 72.7%	0/ 7 0.0%	10/ 14 71.4%	3/ 9 33.3%	2/ 3 66.7%	7/ 11 63.6%	4/ 7 57.1%	7/ 14 50.0%	2/ 9 22.2%
		非発生	30/ 34 88.2%	56/ 61 91.8%	75/ 79 94.9%	39/ 40 97.5%	21/ 23 91.3%	62/ 68 91.2%	118/ 122 96.7%	157/ 158 99.4%	78/ 80 97.5%
		全体	38/ 45 84.4%	56/ 68 82.4%	85/ 93 91.4%	42/ 49 85.7%	23/ 26 88.5%	69/ 79 87.3%	122/ 129 94.6%	164/ 172 95.3%	80/ 89 89.9%

6. N時間幅による検討

本研究で構築するがけ崩れ発生・非発生の判別システムは、最終的に降雨継続中にがけ崩れの発生を事前に予測することを目的としている。そのためには、非発生降雨データとして無降雨の情報(時間雨量0mm/h、累積雨量0mm、継続時間0hr)を学習させる事が有効とされることから最良のケースに無降雨情報を追加し再構築を行った。その結果、表-2の時間雨量のみの判別結果が示すように、火山性岩石ではテストデータに対する判別率が発生・非発生ともに低下する事が分かった。

表-2 火山性岩石における結果(時間雨量基準)

岩石区分		火山性岩石			
N時間幅		(時間雨量のみ)	5	6	7
収束状況	学習回数	5552	1354	1112	1053
	最小二乗誤差	0.000076	0.000074	0.000051	0.000060
正判別率	学習データ	発生	29/ 29 100.0%	29/ 29 100.0%	29/ 29 100.0%
		非発生	347/ 347 100.0%	347/ 347 100.0%	347/ 347 100.0%
		全体	376/ 376 100.0%	376/ 376 100.0%	376/ 376 100.0%
	テストデータ	発生	6/ 14 42.9%	10/ 14 71.4%	11/ 14 78.6%
		非発生	73/ 79 92.4%	79/ 79 100.0%	79/ 79 100.0%
		全体	79/ 93 84.9%	89/ 93 95.7%	89/ 93 96.8%

そこで、発生降雨では崩壊時刻を含むN時間前までの時間雨量を降雨データとして学習させることで、より正確な降雨パターンを判別システムに反映させることができると考えられる。そこでN時間幅雨量(N=5, 6, 7)を用い判別精度の向上を試みた。表-2に示す判別結果を見ると時間雨量のみを用いた場合よりもN時間幅雨量を用いた方が発生・非発生ともにテストデータの判別率が向上していることが分かる。時間幅の違いでは、6時間幅を用いた場合が最も判別率が高いことが分かる。

7. おわりに

本研究で構築したがけ崩れ発生・非発生の判別システムは、岩石区別では、未固結堆積物、火山性岩石で約70%と高い発生判別率が得られることが分かった。またリアルタイム予測を考慮した判別システムを構築した結果、火山性岩石では極端な発生判別率の低下が見られた。この判別精度の向上手法としてN時間幅雨量(N=6)が有効であることが分かった。

今後がけ崩れ発生・非発生判別システムに有効な斜面データ、降雨要因を吟味していくことで発生予想システムの精度を高めていく必要がある。