

## ニューラルネットワークを用いたリアルタイムの急傾斜地の崩壊・未崩壊の判別に関する研究

山口大学工学部大学院 正会員 ○大場眞由美 山口県土木建築部砂防課 正会員 石村和寿  
 山口大学工学部 正会員 菊池英明 山口県土木建築部砂防課 正会員 飛渡一敏  
 山口大学工学部 正会員 古川浩平 中電技術コンサルタント㈱ 正会員 荒木義則

### 1. はじめに

自然災害の中でも土砂災害は、梅雨時期や台風の季節になると毎年全国各地で発生しており、尊い命や貴重な財産が犠牲になっている。また、近年人々の生活域が山麓地や丘陵地にも拡大しており、危険個所の拡大が懸念されている。そこで本研究では、パターン認識に優れているとされるニューラルネットワークモデル(以下、NNモデル)を用い、素因である地形要因と誘因である降雨要因を用いて急傾斜地の崩壊・未崩壊判別システムを構築し、リアルタイム崩壊予測を行なうことにより適用可能性についての検討を行う。

### 2. 使用データ

山口県内 16箇所の降雨観測所を中心に半径 5 km のエリアを設定し、1978 年から 1997 年の 20 年間にエリア内で急傾斜地が崩壊した降雨を崩壊降雨、崩壊降雨と同一エリア内の未崩壊斜面に対して崩壊降雨を未崩壊降雨とする。

降雨要因は N 時間雨量 ( $N = 4 \sim 10$ )、累積雨量、降雨継続時間を基本とし、崩壊降雨は崩壊時刻を降雨抽出点とし、未崩壊降雨は一連の降雨の最大時間雨量を記録した点を降雨抽出点として用いる。また、地形要因には表 1 に示す 20 の要因を用いる。

これらの要因を用いて NN モデルを構築する際には地盤状況別に構築した方が判別能力の向上が見られるため、本研究ではデータ数の多い軟岩と強風化岩に限定し、それぞれ別個に NN モデルを構築する。

### NN モデルによるシステムの構築

#### (1) NN モデルの構築

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、それぞれの要因は各カテゴリーの最大値で 1~0 の間に正規化したの数値ニューロンを用いる。また、出力層のニューロンは急傾斜地の崩壊・未崩壊の 2 個のニューロンを設定している。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  $\leq 0.001$  または最大 10,000 回の反復学習を行った。また、ニューロンの入出力関数はシグモイド関数とした。

#### (2) 検討ケースの設定

本研究では、NN モデルの構築にあたって、中間層の層数を 1 層~3 層、中間層のニューロン数を 5~8 まで変化させ、最適な NN モデルの構造に対して検討を行なった。結果、中間層の層数を 2 層及び 3 層とし、ニューロン数を 8 ニューロンにした場合に最も正解率が得られたため、これら 2 つの構造の NN モデルを用いて両地盤状況について検討を行なう。また、降雨要因として CaseA : N 時間雨量、CaseB : N 時間雨量・累積雨量・降雨継続時間の 2 つのケースを考えた。なお、全てのケ

表 1 地形要因一覧 斜面要因		
地形要因	地質・地形要因	環境要因
延長(m)	地表の状況	植生の種類
傾斜度(°)	表土厚さ(単位cm)	伐採樹の状況
高さ	地盤の状況	崩壊歴性
斜面形状	岩盤亀裂(単位cm)	隣接斜面崩壊歴性
堆積形状	斜面不連続面	湧水の有無
横断形状	断層破碎帶	対策工
遷移線	風化状況	

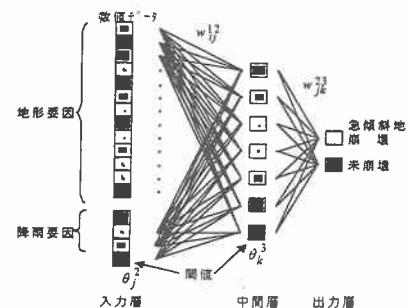


図 1 ニューラルネットワークモデル図

ースにおいて崩壊のデータ数を1~6倍に増やした集中学習を行なった。

### (3) 判別結果

平成6年までのデータを教師データ、平成7年・9年をテストデータとして検討した結果、全体的にはCase Aでは正解率がよいが収束状況が悪く、Case Bでは収束状況がよいが正解率が悪い。また、軟岩では中間層2層ニューロ

ン数8個、強風化岩では中間層3層ニューロン数8個のケースが良い結果を示した。これらの中で良好なケースの正解率を表2に示す。

### 4. リアルタイム崩壊予測

#### (1) リアルタイムの予測と評価

表2に示したケースについてリアルタイム崩壊予測を行なった結果、両地盤状況とも多数の斜面で無降雨時間でも崩壊確信度の上昇が見られた。図3~図4はその例である。ここで学習データのうち、崩壊時刻において時間雨量=0のデータ数は軟岩3、強風化岩8存在するため無降雨時間における崩壊確信度の上昇はこれらの影響を受けていると思われる。また、崩壊データを集中学習した結果、2倍、3倍と増加していくごとに崩壊時刻以外における崩壊確信度の上昇が多くなる傾向が見られ、空振り率が増してしまう。以上のことから次節では、時間雨量=0のデータを削除し、集中学習を行なわずにNNモデルの再構築を行なった。

#### (2) モデルの再構築と評価

時間雨量=0のデータを削除する前と後の

リアルタイム崩壊予測結果の代表例が図6、図7である。これより、データ削除後においても誤判別はあるものの、データ削除前と比べ、改善されたといえる。

#### 5.まとめ

これらの結果より、急傾斜地における崩壊には、崩壊時刻における時間雨量が非常に少ない場合があるため、リアルタイムによる崩壊・未崩壊判断を行なう場合、空振り率が増し、信頼性の低いシステムとなってしまう。この事からNNモデルを構築する際はこのようなデータを削除して降雨要因が誘因となる崩壊に限定して予測を行なうことが望ましい。また、教師データを倍学習させる集中学習は正解率は向上するものの、リアルタイム予測を行なう際は、注意が必要であるといえる。

表2 NNモデル正解率

岩種	層数	岩種				強風化岩			
		ニューロン数		軟岩		2層BN		3層BN	
	層数	Case1	Case2	Case1	Case2	Case1	Case2	Case1	Case2
学習当方	法	5倍学習	3倍学習	2倍学習	6倍学習	5倍学習	6倍学習	1倍学習	4倍学習
入力時刻	間隔	6	6	10	8	6	6	10	8
収束状況	学習回数	10,000	3,739	10,000	686	10,000	987	10,000	4,404
	最小二乗誤差	0.002323	0.000982	0.001359	0.000869	0.004847	0.000929	0.017142	0.000747
正解率	教師データ	発生	22/22	21/22	22/22	20/22	48/48	46/48	28/48
	平成6年	発生	100.0%	95.5%	100.0%	90.9%	100.0%	95.8%	58.3%
	非発生	981/984	984/984	982/984	984/984	1092/1098	1077/1098	1098/1098	1097/1098
	全 体	99.7%	100.0%	99.8%	100.0%	99.5%	99.9%	100.0%	99.9%
精度率	平成7年	発生	3/3	1/3	3/3	2/3	2/4	2/4	3/4
	非発生	353/375	374/375	340/375	375/375	166/176	176/176	176/176	176/176
	全 体	94.2%	97.7%	90.7%	100.0%	94.3%	100.0%	100.0%	100.0%
	平成9年	発生	356/378	375/378	343/378	376/378	168/180	178/180	179/180
	非発生	94.2%	99.2%	90.7%	99.5%	93.3%	98.9%	99.4%	98.9%
	全 体	191/192	192/192	191/192	192/192	179/181	179/181	181/181	181/181

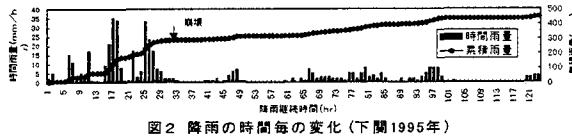


図2 降雨の時間毎の変化(下関1995年)

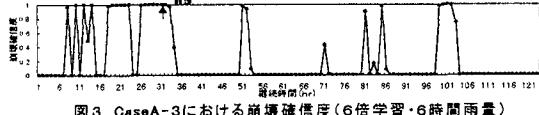


図3 CaseA-3における崩壊確信度(6倍学習・6時間雨量)

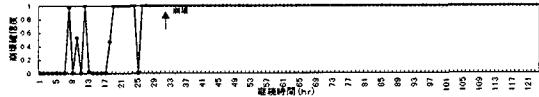


図4 CaseB-3における崩壊確信度(6倍学習・6時間雨量)

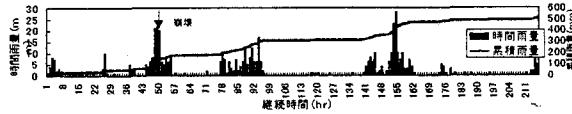


図5 降雨の時間毎の変化(岩国1985年)

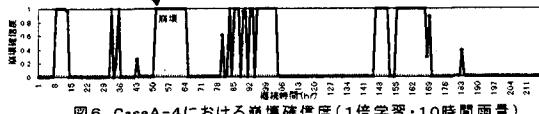


図6 CaseA-4における崩壊確信度(1倍学習・10時間雨量)



図7 CaseA-4における崩壊確信度(1倍学習・10時間雨量)"0"データ削除